


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA PODNIKATELSKÁ  
ÚSTAV MANAGEMENTU

FACULTY OF BUSINESS AND MANAGEMENT  
INSTITUTE OF MANAGEMENT

# HODNOCENÍ ZÁKAZNÍKŮ METODAMI UMĚLÉ INTELIGENCE

CUSTOMER ANALYSIS BY ARTIFICIAL INTELLIGENCE METHODS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Ing. MICHAL BUTELA

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. PETR DOSTÁL, CSc.

BRNO 2009

# **ZADÁNÍ DIPLOMOVÉ PRÁCE**

**Butela Michal, Ing.**

---

Řízení a ekonomika podniku (6208T097)

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách, Studijním a zkušebním řádem VUT v Brně a Směrnicí děkana pro realizaci bakalářských a magisterských studijních programů zadává diplomovou práci s názvem:

**Hodnocení zákazníků metodami umělé inteligence**

v anglickém jazyce:

**Customer Analysis by Artificial Intelligence Methods**

Pokyny pro vypracování:

Úvod

Vymezení problému a cíle práce

Teoretická východiska práce

Analýza problému a současné situace

Vlastní návrhy řešení, přínos návrhů řešení

Závěr

Seznam použité literatury

Přílohy

Seznam odborné literatury:

DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě, CERM, Brno, 2008, 340s, ISBN 978-80-7204-605-8.

MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. Umělá inteligence (4), ACADEMIA, 2003, 475p., ISBN 80-200-1044-0.

HANSELMAN, D., LITTELFIELD, B. Mastering MATLAB 7, Prentice Hall, USA, 2005, 852s., ISBN 0-13-185714-2. VOSS, S.,

THE MATHWORKS. MATLAB – Neural network – User's Guide, The MathWorks, Inc., 2008. THE MATHWORKS. MATLAB – User's Guide, The MathWorks, Inc., 2008.

BOSE, K., LIANG, P. Neural Network, Fundamental with Graphs, Algorithm and Applications, Mc Graw-Hill, USA, 1996, 478s., ISBN 0-07-114064-6.

HAGAN, T., DEMUTH, B. Neural Network Design, PWS Publishing Comp., USA, 1996, 702s., ISBN 0-534-94332-2.

Vedoucí diplomové práce: doc. Ing. Petr Dostál, CSc.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2008/2009.

L.S.

---

PhDr. Martina Rašticová, Ph.D.  
Ředitel ústavu

---

doc. RNDr. Anna Putnová, Ph.D., MBA  
Děkan fakulty

V Brně, dne 22.05.2009

## **Abstrakt**

Tato práce se zabývá hodnocením zákazníků školicího centra. Předmětem zkoumání jsou dotazníky, které vyplňují účastníci po skončení kurzu. Na zpracování jsou použité metody umělé inteligence. Hodnocení spokojenosti s kurzy je dosaženo fuzzy logikou. Shlukování zákazníků dle společných vlastností je dosaženo neuronovými sítěmi. Na konci je vyhodnocení a návrhy na zlepšení ekonomické výkonnosti.

## **Klíčová slova**

hodnocení zákazníků, dotazníky, školicí centrum, fuzzy logika, neuronové sítě

## **Summary**

This thesis is focused on learning center customer satisfaction. The object of research is surveys filled by courses' participants. Artificial intelligence methods are used for data processing. The courses' quality measurement is achieved by fuzzy logic. Customer clustering is achieved by neural networks. At the end of document is data evaluation and proposals for economics effectiveness increase.

## **Keywords**

customer analysis, surveys, learning center, fuzzy logic, neural networks

## Citace

BUTELA, M. *Hodnocení zákazníků metodami umělé inteligence*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. 65 s. Vedoucí diplomové práce doc. Ing. Petr Dostál, CSc.

# **Hodnocení zákazníků metodami umělé inteligence**

## **Prohlášení**

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením doc. Ing. Petra Dostála, CSc.

Další informace mi poskytli Erik Caha a Silvie Čečelská.

Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....  
Michal Butela  
15.5.2009

## **Poděkování**

Chci se poděkovat všem, kteří mi pomohli při vytvoření této práce. Zejména mému vedoucímu práce a konzultantovi.

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě podnikatelské. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

Obsah.....	1
1 Úvod.....	3
2 Ciele práce a metódy spracovania.....	4
3 Školiace centrum GOPAS a.s.....	5
3.1 Popis spoločnosti.....	5
3.2 Právna forma a predmet podnikania.....	7
3.3 Organizačná štruktúra.....	10
4 Analýza súčasného stavu.....	11
5 Umelá inteligencia a ekonomika.....	12
5.1 Fuzzy logika.....	13
5.1.1 Matematický popis.....	14
5.1.2 Aritmetické operácie na fuzzy množinách.....	15
5.1.3 Proces fuzzy spracovania.....	18
5.2 Neurónové siete.....	20
5.2.1 Princíp fungovania neurónovej siete.....	22
5.2.2 Príklad použitia neurónovej siete.....	24
6 Rozbor zákazníkov.....	26
6.1 Hodnotenie spokojnosti zákazníkov.....	26
6.1.1 Postup hodnotenia.....	26
6.1.2 Získanie a úprava dát.....	27
6.1.3 Vyhodnotenie dát.....	28
6.1.4 Príklad.....	33
6.1.5 Interpretácia výsledkov.....	36
6.2 Klasifikácia zákazníkov.....	37
6.2.1 Hodnotiace kritériá zákazníkov.....	38
6.2.2 Úprava vstupných dát.....	39
6.2.3 Spracovanie dát.....	40
6.2.4 Vyhodnotenie dát.....	41
7 Zhodnotenie výsledkov.....	48
7.1 Opatrenia .....	48
8 Záver.....	50



Literatúra.....	51
Zoznam obrázkov.....	52
Zoznam tabuliek.....	53
Zoznam príloh.....	54

# 1 Úvod

Zákazníci, ich dobrá znalosť a celková spokojnosť je jedným z kľúčových predpokladov pre úspešné podnikanie. Preto by sme mali našich zákazníkov dobre spoznať a vyhodnotiť, klasifikovať. To žiaľ nie je úplne jednoduché. Do hry vstupuje množstvo faktorov a mi ich musíme všetky brať do úvahy. Nie je možné jednoducho rozhodnúť, ktorý zákazník je spokojný, resp. nespokojný, ktorý je perspektívny, resp. ne-perspektívny. Na hodnotenia tohto typu, ktoré prebieha k komplexných podmienkach musíme siahnuť po mocnejšom nástroji. Jedným z nich je umelá inteligencia a jej algoritmy.

Toto je oblasť, ktorá ma zaujala a je možné ju s výhodou aplikovať na riešenie rôznych ekonomických problémov. Pod pojmom umelá inteligencia si môže mnoho nezainteresovaných osôb predstaviť niečo príliš komplikované, futuristické a nepochopiteľné. My si pod tým ale predstavíme množinu algoritmov, ktoré môžeme s výhodou využiť. Patrí sem fuzzy logika, neurónové siete, genetické algoritmy, expertné systémy a ďalšie. Fuzzy logiku najčastejšie využívame na hodnotenie a klasifikovanie, v prípade, kde sa musíme rozhodnúť podľa mnohých faktorov. Príkladom môže byť výber spôsobu uloženia voľných disponibilných prostriedkov, či zhodnotenie rizika pri expanzii na nové trhy. Neurónové siete dávajú zaujímavé výsledky pri predikatívnych úlohách. Jednou z nich je predpoveď vývoja cien akcií na burze. Inou oblasťou je klasifikácia, resp. zhlukovanie. Genetické algoritmy môžu byť efektívnou alternatívou pre výpočtovo náročné algoritmy, ale poslúžia aj pre vyhľadanie vhodnej kombinácii vstupov pre maximálny zisk, či minimálne náklady.

Po úspešnom vyhodnotení našich zákazníkov môžeme zistené skutočnosti s výhodou využiť pre zvyšovanie finančnej výkonnosti našej firmy. Obdržané informácie pomáhajú manažérom správne sa rozhodovať a dosahovať vytýčené ciele. Následne môžu byť využívané či už v marketingu, logistike alebo pri udržiavaní vzťahov so zákazníkmi.

## 2 Ciele práce a metódy spracovania

Mojím prvým cieľom bude tieto zložité hodnotenia vyjadriť v jednoduchšej a jednoznačnej forme. Ďalším dôležitým faktorom pre budúci rozvoj a prosperitu firmy je dobre spoznanie svojich zákazníkov. Nápomocným nástrojom je ich rozdelenie do skupín – zhlukovanie. Z týchto zhlukov vypozerujeme spoločné črty, ktoré by nemuseli byť na prvý pohľad pozorovateľné. Táto klasifikácia je mojím druhým cieľom.

Pre potrebu tejto diplomovej práce som si zvolil prácu s fuzzy logikou a neurónovými sieťami. Fuzzy logiku využívam na komplexné hodnotenie spokojnosti zákazníkov. Neurónové siete pre ich zhlukovanie do skupín s podobnými znakmi. Firma na ktorú budem uvedené postupy aplikovať je školiace centrum Gopas a.s. Táto spoločnosť sa zaoberá poskytovaním služieb v oblasti IT vzdelávania. Jej hlavným poslaním je poskytovať školenia tak aby bol zákazník čo najspokojnejší. Zákazníci po skončení školenia vyplňajú pomerne rozsiahle dotazníky.

Pre samotné spracovanie a vyhodnotenie dát použijem existujúce softwarové vybavenie. To je v testovacích verziách voľne dostupné na stránkach výrobcov. Pre plné vyžitie musíme ale zakúpiť potrebné licencie. Zámerne som zvolil tento prístup. Je totiž jednoduchý, rýchly, s okamžitými výsledkami. Vyhol som sa nutnosti programovať jednotlivé metódy v nejakom z bežných programovacích jazykov. To nie je v princípe príliš obtiažne, ale nezodpovedá do pracovnej náplni ekonóma.

V jednotlivých kapitolách tejto práce popisujem princípy fungovania fuzzy logiky a neurónových sietí, vrátane možností aplikácie. V ďalších častiach sa venujem rozboru dát a použitiu vhodného software na ich vyhodnotenie. Napokon ponúkam interpretáciu zistených výsledkov a ich možný prínos pre samotnú firmu do budúcnosti. V sekcii venujúcej sa spracovaniu je zahrnutý aj stručný popis ako dané programy nastaviť a používať.

### 3 Školiace centrum GOPAS a.s.

Ako predmet skúmania pre svoju diplomovú prácu som si vybral spoločnosť GOPAS a.s. Je to firma s ktorou spolupracujem a preto mi bolo umožnené zacieliť na ňu aj túto prácu. Firma GOPAS a.s je zameraná na poskytovanie školení v oblasti informačných technológií a moja kooperácia má formu externej spolupráce. V spoločnosti pracujem ako odborný lektor.



*Obrázok 1: Logo spoločnosti GOPAS*

#### 3.1 Popis spoločnosti

Spoločnosť GOPAS a.s. vznikla v roku 1992 a od svojich prvopočiatkov sa sústreďí na školenie v oblasti informačných technológií a manažérskych schopností. Dôkladným dodržiavaním tejto stratégie a dbaním na kvalitu sa prepracovala na špičku v tejto oblasti. Firma si zakladá na úzkej spolupráci s dodávateľmi produktov IT ako aj na vzťahu so svojimi zákazníkmi.

Spoločnosť GOPAS v súčasnosti prevádzkuje tri školiace centrá v Prahe, Brne a Bratislave. Celkovo disponuje 41 učebňami a niekoľkými mobilnými učebňami tvorenými prenosnými počítačmi. Firma GOPAS je autorizovaným partnerom najznámejších firiem v oblasti IT, ako napríklad Microsoft, Oracle, IBM, SUN Microsystems, Adobe, Apple, Corel, SCO. Zároveň je autorizovaným testovacím centrom Prometric a Pearson VUE a testovacím strediskom pre získanie ECDL.

Spoločnosť v súčasnosti zamestnáva približne 50 zamestnancov a spolupracuje s viac ako 100 externými spolupracovníkmi. Spokojnosť zákazníkov so službami je na prvom mieste, o čom svedčí aj získanie certifikátu ISO 9001 a akreditácie Ministerstva školství, mládeže a tělovýchovy pre rekvalifikácie.

Medzi dôvody úspechu firmy môžeme zaradiť výlučné zameranie na školenia. Firma sa venuje len vzdelávacím kurzom, prípadne organizovaniu technických konferencií. Vďaka tejto úzkej špecializácii je bolo možné dosiahnuť vysokú kvalitu poskytovaných služieb. Ďalším dôvodom je orientácia na potreby zákazníkov. Kurzy sú vypisované podľa aktuálneho dopytu. V ponuke je v súčasnosti viac než 1400 kurzov a sú priebežne aktualizované pre najnovšie verzie školených produktov. Firma GOPAS pripravuje vlastné školenia na tematiku, pre ktorú neexistujú oficiálne výukové kurzy.

Jednotlivé kurzy sú prehľadne rozdelené do kategórií. Tie sú ďalej členené do podkategórií. Medzi hlavné kategórie môžeme zaradiť: kancelárske programy, správa serverov a sietí, databáze, úprava obrazu a videa. Tie sú rozčlenené. Napríklad pod kategóriou správy sietí nájdeme sekcie produktov Microsoft, SUN, Linux, Apple a podobne.



*Obrázok 2: Mobilná učebňa*

Medzi ďalšie aspekty, ktoré udržiavajú celkovú kvalitu, môžeme zaradiť vysoko kvalifikovaný lektorský zbor. Všetci lektori musia disponovať vysokými technickými znalosťami, ale zároveň aj dobrými prezentačnými schopnosťami. Vždy sa u nich vyžadujú certifikácie na produkty, ktoré vyučujú. Medzi ne patrí certifikát Microsoft Certified Trainer a mnoho ďalších

Okrem technických kurzov sú poskytované aj tzv. soft-skills kurzy zamerané na manažérov. Tu nájdeme školenia na podporu IT procesov na báze štandardov ITIL a COBIT. V zozname sa nachádza aj time-management alebo prezentačné schopnosti. Posledný spomínaný je realizovaný ako kurz Master of Presentation Skills. Ten patrí medzi veľmi renomované. [4]

## 3.2 Právna forma a predmet podnikania

Datum zápisu:	1.dubna 1996
Obchodní firma:	GOPAS, a.s.
Sídlo:	Praha 10, Kodaňská 1441/46, PSČ 101 00
Identifikační číslo:	639 11 035
Právní forma:	Akciová společnost
Předmět podnikání:	<ul style="list-style-type: none"> <li>- školící činnost v oboru výpočetní techniky</li> <li>- poradenská činnost v oboru výpočetní techniky</li> <li>- činnost organizačních a ekonomických poradců</li> <li>- reklamní činnost</li> <li>- nakladatelská a vydavatelská činnost</li> <li>- koupě zboží za účelem jeho dalšího prodeje a prodej</li> <li>- kopírovací práce</li> </ul>
Statutární orgán - představenstvo:	
předseda představenstva:	ing. Petr Daniel
místopředseda představenstva:	ing. Petr Dvořák
člen představenstva:	ing. Ladislav Bartoníček
Jednání jménem společnosti:	Za společnost jedná předseda představenstva, a to samostatně, nebo místopředseda představenstva, a to rovněž samostatně. Podepisování za společnost se děje tak, že k napsanému, vytištěnému nebo otištěnému názvu společnosti připojí svůj podpis osoba oprávněná jednat za společnost.
Dozorčí rada:	
předseda dozorčí rady:	ing. Eva Danielová
člen dozorčí rady:	ing. Petr Pokorný
člen dozorčí rady:	ing. Eva Joštová
Akcie:	100 ks kmenové akcie na jméno ve jmenovité hodnotě 10 000,- Kč v listinné podobě
Základní kapitál:	1 000 000,- Kč

*Tabulka 1: Výpis z obchodního registra ČR*

Právna forma podnikania spoločnosti GOPAS je akciová spoločnosť. Táto forma je vhodnejšia práve pre väčšie firmy. Na rozdiel od mnohých spoločností s ručením obmedzeným, predstavuje spoľahlivého obchodného partnera. Základný vklad spoločnosti je 1 000 000 Kč, čo je výrazne vyššia čiastka než u väčšiny firiem formy s.r.o. Základný kapitál je rozdelený na 100 akcií. Každá z nich má hodnotu 10 000 Kč. S akciami nie je verejne obchodované na žiadnej burze. [7]

Medzi hlavné predmety podnikania patrí najmä školiaca a poradenská činnosť v obore výpočtovej techniky. Medzi doplnkové predmety podnikania radíme nakladaciu, vydateľskú činnosť a kopírovanie. To je zviazané s produkciou vlastných príručiek pre niektoré kurzy. Jedná sa najmä o kurzy zamerané na kancelárske programy a tiež vlastné GOC kurzy. Medzi dodatkové činnosti patrí aj nákup tovaru za účelom jeho ďalšieho predaja. To v praxi pokrýva hlavne nákup príručiek k oficiálnym kurzom priamo od výrobcu a ich predaj účastníkom.

Spoločnosť GOPAS má hlavné sídlo v Prahe. Ďalšia pobočka sa nachádza v Brne. Postupným rozširovaním sa dostala firma aj na slovenský trh. V súčasnosti je na území SR lokalizovaná jedna pobočka v Bratislave. Od roku 2004 má táto pobočka samostatnú právnu formu. Jedná sa o akciovú spoločnosť GOPAS SR a.s. Je zapísaná v obchodnom registri SR. Je charakteristiky sú veľmi podobnej českej a.s. Pre úplnosť prikladám výpis z registra SR.

[8]



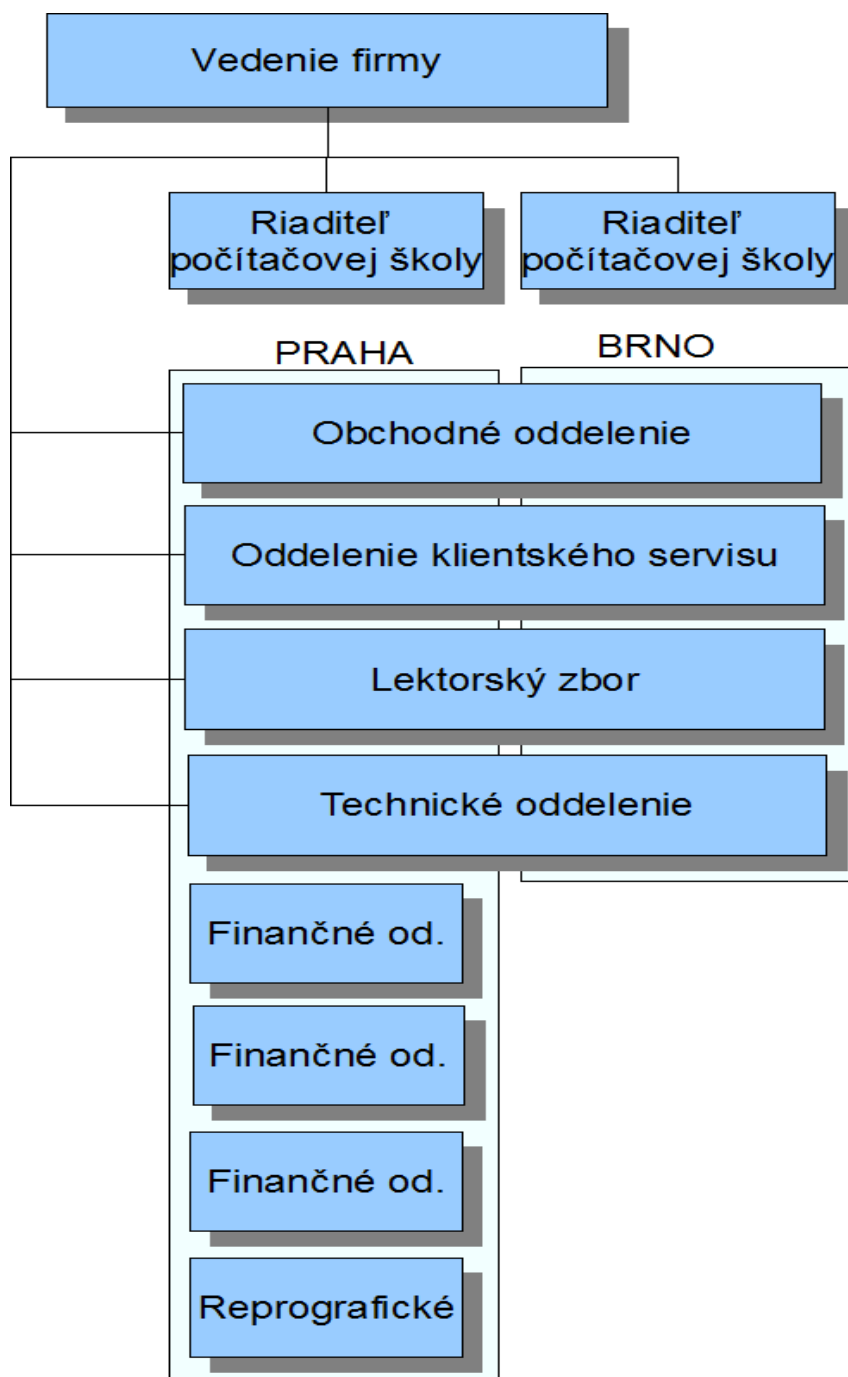
*Obrázok 3: Učebňa v priestoroch firmy*

Obchodné meno:	GOPAS SR, a.s.
Sídlo:	Dr.Vladimíra Clementisa 10 Bratislava 821 02
IČO:	35 881 674
Deň zápisu:	07.04.2004
Právna forma:	Akciová spoločnosť
Predmet činnosti:	<ul style="list-style-type: none"> <li>- kúpa tovaru na účely jeho predaja konečnému spotrebiteľovi</li> <li>- kúpa tovaru na účely jeho predaja iným prevádzkovateľom živnosti</li> <li>- poradenská činnosť v oblasti nákupu a predaja tovarov</li> <li>- sprostredkovateľská činnosť v oblasti nákupu a predaja tovarov a - sprostredkovanie služieb</li> <li>- prenájom hnuiteľných vecí - spotrebný a priemyselný tovar</li> <li>- činnosť reklamnej agentúry</li> <li>- vydávanie periodickej a neperiodickej tlače</li> <li>- organizovanie kurzov, seminárov a školení</li> <li>- školiaca činnosť v oblasti výpočtovej techniky</li> <li>- kopírovacie práce</li> <li>- prieskum trhu</li> <li>- výroba, rozmnožovanie a nahrávanie zvukových a zvukovoobrazových záznamov so súhlasom autora</li> </ul>
Štatutárny orgán:	predstavenstvo
	Ing. Petr Daniel - predseda predstavenstva Ján Dvořák - podpredseda predstavenstva Ing. Andrea Horáčková
Konanie menom spoločnosti:	Za spoločnosť konajú a podpisujú predseda predstavenstva samostatne, člen predstavenstva spoločne s predsedom, alebo podpredsedom predstavenstva spoločne. Za spoločnosť konajú a podpisujú tak, že k obchodnému menu alebo pečiatke spoločnosti pripoja svoje podpisy
Základné imanie:	1 000 000 Sk Rozsah splatenia: 1 000 000 Sk
Počet, druh, podoba a menovitá hodnota akcií:	Počet akcií: 100 kmeňové , listinné Menovitá hodnota jednej akcie: 10 000 Sk
Dozorná rada:	Ing. Jitka Krákorová Ing. Eva Danielová Andrej Meravý

Tabuľka 2: Výpis z obchodného registra SR



### 3.3 Organizačná štruktúra



Obrázok 4:

Organizačná štruktúra GOPAS a.s.

## 4 Analýza súčasného stavu

Súčasný stav na trhu vzdelávania v IT je horší než to bolo v nedávnej minulosti. Jedným z dôvodov je aj pretrvávajúca vlna hospodárskej represie. Práve v tomto období siaha mnoho firiem po úsporných opatreniach. Jedným z nich je obmedzovanie vzdelávacích programov zamestnancov. Práve preto v tomto období registrujeme menší pokles počtu záujemcov o služby. V služby akými sú aj školenia v oblasti IT preto pozorujeme ubúdajúcu tendenciu zákazníkov. Pre lepšie pochopenie situácie môžeme siahnuť po často používanom nástroji akým je SWOT analýza. V nej budeme sumarizovať slabé a silné stránky spoločnosti, príležitosti a hrozby.

Silné stránky (strength)	Slabé stránky (weakness)
<ul style="list-style-type: none"> <li>• majoritný podiel na trhu v oblasti školení IT</li> <li>• úzka spolupráca s dodávateľmi technológií</li> <li>• dobré meno spoločnosti a dlhoročná reputácia</li> <li>• najširšia ponuka kurzov a ich vysoká úroveň</li> <li>• kvalitná lektorská základňa</li> <li>• reprezentatívne a vybavené priestory</li> <li>• program ochrany získaných znalostí</li> <li>• nadštandardná starostlivosť o zákazníkov</li> </ul>	<ul style="list-style-type: none"> <li>• najvyššie ceny služieb na trhu</li> <li>• nižšia flexibilita u kurzov na mieru</li> <li>• zložité komunikačné kanály v spol.</li> </ul>
Príležitosti (opportunities)	Hrozby (threads)
<ul style="list-style-type: none"> <li>• využitie programov EU: <i>Vzdělávejte se!</i> a <i>Školení je šance!</i></li> <li>• alternatívne školenia v podobe večerných kurzov</li> <li>• zníženie ceny príručiek k oficiálnym kurzom</li> </ul>	<ul style="list-style-type: none"> <li>• agresívna cenová politika konkurenčných stredísk</li> <li>• odchod lektorov do iného sektoru alebo ku konkurencii</li> <li>• strata stálej klientely následkom zmien vo vedení firmy</li> </ul>

Tabuľka 3: SWOT analýza

## 5 Umelá inteligencia a ekonomika

Pojem umelá inteligencia je dnes často skloňovaný a používaný. Pre neznalých to môže vzbudzovať nadsadené predstavy robotov z vedecko-fantastických filmov. My však vieme, že táto pojem zahŕňa skupinu algoritmov, na základe ktorých sa výpočtová technika dokáže rozhodovať podobne ako by sa rozhodol človek. Súčasný stav nám umožňuje využívať UI prevažne na jednoúčelové úlohy. Väčšinu z nich by bolo možné zvládnuť klasickým prístupom, avšak dopracovanie sa k výsledku by trvalo výrazne dlhšie. Kombináciou UI a výpočtovej techniky sa dostávame k veľmi zaujímavým výstupom v prijateľnom čase. Pojem umelá inteligencia zahŕňa niekoľko známych metód a prístupov.

Medzi najjednoduchšie z nich patria expertné systémy. Je to v podstate jednoduchá databáza s definovanými otázkami. Podľa odpovede je respondent smerovaný na ďalšie otázky tak, aby sa napokon dopracoval k zdroju svojho problému a dostal navrhované riešenie. Väčšinou sa realizuje vo forme jednoduchého dotazníkového programu. Využitie to môže mať pri diagnostike zdravotných problémov ľudí a zvierat, ale aj pre odhaľovanie technických problémov napr. u áut. Nevýhodou expertného systému je jeho statickosť a uzavretosť. Jeho autor doň vloží množinu výsledkov a otázky, ktoré zostaví do stromovej štruktúry. Následne kladie otázky od generických až po najviac špecifické. V prípade, že problém respondenta nieje zahrnutý v databáze, tak sa nedopracuje k žiadnemu výsledku, prípadne sa dostane k nesprávnemu záveru. Celkové využitie v oblasti ekonomiky je slabšie.

Zaradiť sem môžeme aj genetické algoritmy. Tie sú inšpirované prírodnými procesmi genetického vývinu. Podobne ako v prírode, aj tu funguje kríženie, dedičnosť a mutácie. Pri tomto spôsobe musíme problém zakódovať do reťazca číslíc, ktorý reprezentuje jedinca. Definujeme tvar reťazcu cieľového riešenia. Začneme tak, že generujeme počiatočnú populáciu a jednotlivcov medzi sebou krížime. Sledujeme stupeň zhody s cieľovým riešením. Vyberáme najvhodnejších potomkov z populácie a postup kríženia opakujeme. Za pomerne krátky čas sa môžeme, ale aj nemusíme dostať k výsledku. Tento postup nie je vhodný na každú úlohu, problém musí byť matematicky popísateľný. Ďalším problémom je tzv. čas konverencie. Teda rýchlosť akou sa dostaneme k cieľovému stavu. Ten môže byť veľmi krátky, ale aj neprijateľne dlhý. Veľkú rolu tu zohráva náhoda. Zaujímavosťou je, že sa občas dostaneme ku riešeniam, ku ktorými by sme sa konvenčnými spôsobmi nikdy nedopracovali. Jednou z aplikácií v praxi je návrh hradlových polí, ktoré slúžia napríklad ako filter pre spracovanie snímaného obrazu, alebo pre rozpoznávanie objektov na snímanom

obrazu. V oblasti ekonomiky je tento postup využiteľný napríklad pri hľadaní minimálneho alebo maximálneho riešenia. Minimálne náklady, maximálna efektivita pri výrobe za použitia dostupných zdrojov. Tieto úlohy môžeme zväčša riešiť simplexovou metódou alebo algoritmom VAM. Využiteľnosť je menšia. [1]

Najčastejšie sa v ekonomickej oblasti používa fuzzy logika a neurónové siete. Týmto dvom metódam sa budeme venovať v nasledujúcich samostatných kapitolách.

## 5.1 Fuzzy logika

Fuzzy logika je založená na fuzzy množinách. Tie rozširujú tradičné ponímanie množín. V tradičných množinách definujeme jasne a ostro, ktoré prvky sú členom a ktoré nie sú členom danej množiny. Vo fuzzy množinách toto členstvo nie je tak jednoznačné. Pojem fuzzy znamená nejasný alebo neostrý. Preto členstvo prvku v danej množine je relatívne. Namiesto jednoznačnej príslušnosti 1 / 0, udávame stupeň príslušnosti v jemnom rozmedzí týchto hodnôt.

Prvé zmienky o teóriách pracujúcich s pravdepodobnosťou sa objavili až v dvadsiatom storočí. Narušili tradičný prístup k logike, ktorá pochádzala ešte z dôb Aristotela. V roku 1930 navrhol Jan Lukasiewicz viac-hodnotovú diskretnú logiku. V roku 1960 vyvinul Arthur Dempster teóriu dokázateľnosti, ktorá zahrňovala možnosť absencie informácií. V roku 1965 navrhol Lotfi Zadeh prvotnú ideu logiky so spojitými hodnotami. Nazval ju fuzzy teória. V osemdesiatych rokoch ukázali ďalší vedci vzťah medzi teóriou dokázateľnosti a teóriou pravdepodobnosti pomocou fuzzy mier.

Pri riešení ekonomických alebo technických problémov môžeme naraziť na nepresne definované informácie. Problém môže byť popísaný nekompletné, nepresne, čiastočne, vágne či rozporuplne. Ak získavame čoraz viac informácií o probléme, tak sa zmenšuje naša neistota pre jeho popis a riešenie. Problémy, ktoré sú nedostatočne charakterizované sú označované ako komplexné alebo nedostatočne objasnené. Tieto problémy sú obkolesené neistotou. Neistota môže mať rôzne formy, ako: fuzzy (neostrá, nejasná, nepresná), môže byť vágna (nešpecifikovaná, amorfná), môže byť viaczmyselná (príliš veľa možností), alebo to môže byť forma prirodzenej variability (náhodná, chaotická, nepredpovedateľná). Týmto formám neistoty sa priradzovali rôzne označenia. Lotfi Zadeh to zjednodušene popisuje praktickým príkladom osoby, ktorá sa má vrátiť z určitého miesta v istý čas. Ak daná osoba popíše svoj návrat slovami: „Vrátim sa čoskoro.“, tak sa jedná o vágny popis. Ak to popíše vetou: „Vrátim sa o pár minút“, tak sa jedná o fuzzy popis. Prvý popis si nevieme spojiť so

žiadnou merateľnou jednotkou času, ako dni, hodiny, minúty. V druhom prípade vieme, že máme počítať rádovo v minútach.

Vágnosť môže byť použitá na popis nejakej neistoty spojením s lingvistickou informáciou alebo intuitívnym chápaním. Ako príklad vágnej informácie môžeme uviesť dáta, ktoré sú označené ako „dobré“, alebo priehľadnosť optického prvku, ktorá je označená ako „prijateľná“. Každopádne termíny vágny a fuzzy nemôžu byť považované za synonymá. Zadeh tvrdí, že väčšinou je možné vágny výrok považovať za fuzzy. Ale neplatí to naopak.

Diskusiu o vágnosti začal už v roku 1937 známy filozof Max Black. Black definoval vágny výrok, ako výrok, kde možné stavy nie sú jasne definované, s prihliadnutím za uzavrenie. Ako príklad uviedol výrok: „Človek je mladý“. Označenie „mladý“ je rozlične interpretované rôznymi ľuďmi. Preto nemôžeme jasne povedať, koľko má označená osoba rokov. Klasická binárna logika nepočíta s takýmito situáciami a preto musíme zaviesť novú metódu interpretácie. [3]

### 5.1.1 Matematický popis

Matematicky to môžeme vyjadriť nasledovne. Členstvo prvku v množine vyjadríme funkciou:


$$\mu_A : x \rightarrow \{0,1\}$$

To znamená, že prvok množine patrí ak výsledok funkcie je:  $\mu_A(x)=1$ , prvok množine nepatrí ak výsledok funkcie je  $\mu_A(x)=0$ .

Členstvo vo fuzzy množine vyjadríme funkciou, ktorej obor hodnôt je z množiny reálnych čísel

$$\mu_A : x \rightarrow \langle 0,1 \rangle$$

Teda čím bližšie je výsledok funkcie pre daný prvok k hodnote 1, tým je väčšia miera príslušnosti k danej množine. Hodnota 1 znamená úplne členstvo. Hodnota 0 znamená žiadne členstvo. Funkcie členstva môžu mať rôzne priebehy. Bežné priebehy členských funkcií sa označujú :  $\Lambda$ ,  $\pi$ , S, Z :



Obrázok 5: Tvary základných členských funkcií

Niektoré členské funkcie ale môžu mať aj zložitejší popis s komplikovanejšie priebehy.

Uvedieme matematický popis funkcie aj jej grafické vyjadrenie: [2]


$$x \in [0, 2] : \mu_A(x) = 0$$

$$x \in [2, 3] : \mu_A(x) = x - 2$$

$$x \in [3, 5] : \mu_A(x) = 1$$

$$x \in [5, 6] : \mu_A(x) = -x + 5$$

$$x \in [6, 8] : \mu_A(x) = 0$$



Obrázok 6: Príklad členskej funkcie


### 5.1.2 Aritmetické operácie na fuzzy množinách

Pri aplikácii aritmetických operácií na klasické množiny sa riadime známymi pravidlami. Výsledky operácií môžeme vyjadriť napríklad graficky pomocou Venových

diagramov. Pri fuzzy množinách musíme dodržiavať iné pravidlá. Najprv aplikujeme aritmetickú operáciu na členské funkcie a dostaneme výslednú členskú funkciu. Z nej vyjadríme stupeň príslušnosti jednotlivých prvkov do výslednej množiny. Pod základnými aritmetickými operáciami si predstavíme: sčítanie, odčítanie, násobenie, delenie, prienik, zjednotenie a doplnok. Pre jednotlivé operácie uvedieme matematický popis aplikácie aj grafické vyjadrenie: [2]

sčítanie:  $[a,b] + [c,d] = [a+c, b+d]$


príklad:  $[4, 8] + [2, 4] = [6, 12]$



Obrázok 7: Sčítanie na fuzzy množinách

odčítanie:  $[a,b] - [c,d] = [a-d, b-c]$

príklad:  $[4, 8] - [2, 4] = [0, 6]$



Obrázok 8: Odčítanie na fuzzy množinách


násobenie:  $[a, b] \times [c, d] = [\min(ac, ad, bc, bd), \max(ac, ad, bc, bd)]$

príklad:  $[4, 8] \times [2, 4] = [8, 32]$

delenie:  $[a, b] / [c, d] = [\min(a/c, a/d, b/c, b/d), \max(a/c, a/d, b/c, b/d)]$


príklad:  $[4, 8] / [2, 4] = [1, 4]$

prienik:  $\mu(x \wedge y) = \min(\mu_x, \mu_y)$



Obrázok 9: Prienik fuzzy množín


zjednotenie:  $\mu(x \vee y) = \max(\mu_x, \mu_y)$



Obrázok 10: Zjednotenie fuzzy množín



doplnok:  $\mu(\neg x) = 1 - \mu(x)$



Obrázok 11: Doplnok fuzzy množiny


### 5.1.3 Proces fuzzy spracovania

Spracovanie dát pomocou fuzzy logiky väčšinou využívame pre rozhodovacie úlohy. V nich máme niekoľko vstupných faktorov s rôznymi hodnotami a rôznou váhou dôležitosti. Vstupné dáta najprv vyjadríme číselne a podľa aktuálnej hodnoty a členskej funkcie začleníme do fuzzy množiny. Priradíme slovný popis, ktorý reprezentuje množinu. Proces spracovania vstupných dát pomocou fuzzy logiky sa nazýva fuzzyfikácia. Nasleduje druhý krok vo výpočte. Ten sa nazýva fuzzy interferencia. Pri ňom vyhodnotíme všetky vstupy a dostaneme výslednú hodnotu. Vyhodnotenie je realizované pomocou tabuľky pravidiel. V nej musia byť popísané všetky kombinácie vstupných hodnôt. Presnejšie členstvo jednotlivých vstupných hodnôt vo fuzzy množinách. Treťou a poslednou fázou je interpretácia výsledku. Hovoríme mu de-fuzzyfikácia. Výstupom fuzzy interferencie je číselná hodnota, alebo členstvo v jednej z fuzzy množín. Túto veličinu interpretujeme do logicky jednoznačného záveru. Napríklad pri danej kombinácii vstupov je pre nás výsledok výhodný / nevýhodný. Zjednodušene to môžeme znázorniť nasledovne:



Obrázok 12: Proces fuzzy spracovania

Ako príklad môžeme uviesť výber z ponuky termínovaných vkladov. Pri výbere zvažujeme niekoľko parametrov. Napríklad výšku úroku, minimálny vklad, doba viazanosti, výška pokuty za predčasný výber, výška poplatkov. Každý z nich ohodnotíme číselnými hodnotami a pomocou vhodnej členskej funkcie zaradíme do fuzzy množiny. Uvedieme si príklad výšky vkladu, pre ostatné vstupy pracujeme analogicky.



Obrázok 13: Členské funkcie pre percento úročenia

V druhom kroku prevedieme tzv. fuzzy interferenciu. Tá je realizovaná pomocou skupiny pravidiel. Príklad pravidla je:

AK úrok=stredný A vklad=nízky A doba viazanosti=krátka A pokuta=stredná A poplatok = žiadny

POTOM termínovaný vklad = viac výhodný

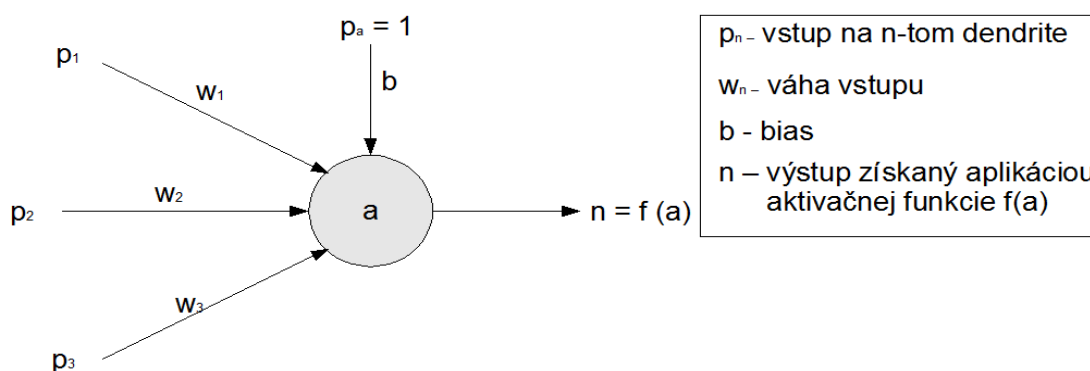
V tretej fáze zavedieme podmienku: viac výhodný a veľmi výhodný znamená: Okamžite založiť účet.

[2]

## 5.2 Neurónové siete

Pod pojmom neurónové siete, si predstavíme umelé neurónové siete, ktoré sú veľmi zjednodušeným modelom biologickej neurónovej siete. Jedná sa teda o primitívny model ľudského mozgu. Ten samozrejme nemusíme hmotne zhotoviť, ale modelujeme ho pomocou výpočtovej techniky. Neurónové siete majú schopnosť riešiť problémy, sú ťažko predikovateľné, resp. problémy, ktoré závisia na veľkom počte faktorov meniacich sa v čase. Tieto faktory a teda aj prostredie majú na prvý pohľad stochastické chovanie. Výhodou neurónovej siete je, že dokáže vypozerovať isté stopy chovania sa prostredia a na ich základe sa rozhodovať. Sieť teda funguje v dvoch fázach. Prvá fáza je takzvaná fáza učenia sa. Druhá fáza je už samotný proces rozhodovania sa na základe aktuálneho stavu prostredia. Zaujímavosťou je, že je prakticky nemožné presne popísať fungovania a nastavenia siete po fáze učenia. Neurónové siete, sa niekedy nazývajú čiernou skrinkou. Pri nastavení siete ide o priradenie správnych váh k jednotlivým vstupom tak, aby sme dostali požadovaný výstup. Toto nastavenie môže byť manuálne alebo automatické. Pre presnejšie pochopenie tohto procesu si najprv vysvetlíme skladbu základného stavebného bloku – neurónu.

Základným predpokladom pre vznik umelých neurónových sietí bolo pochopenie základného princípu funkcie ľudského mozgu. Jeho základným stavebným blokom je neurón. Ten má niekoľko kratších vstupných vlákien – dendrity a jedno dlhé výstupné vlákno – axon. Neurón reaguje na signály na dendritoch, vyhodnotí ich a výsledok vyšle na axon. Veľmi podobne funguje aj umelý neurón. Má niekoľko vstupov a tie majú priradené rôzne váhy. Neurón spočíta hodnoty všetkých vstupov a výsledok vyšle na výstup. Na výstupe je ešte takzvaná aktivačná resp. transformačná funkcia. Jej úlohou je výstup normalizovať, aby sme dostali hodnoty vždy len v určitom rozumnom rozsahu hodnôt.




Obrázok 14: Model umelého neurónu

Jednotlivé vstupy sú označené  $p_n$  a ich váhy sú  $w_n$ . Bias je hodnota, ktoré sa vždy pripočíta k súčtu vstupov. Celkovú hodnotu vstupov získame nasledovným vzorcom:


$$a = w_1 \cdot p_1 + w_2 \cdot a_2 + \dots + w_n p_n + b = \sum_{i=1}^n w_i \cdot p_i + b$$

Z tejto hodnoty vstupov vypočítame finálnu hodnotu výstupu pomocou tzv. aktivačnej funkcie. Postupujeme nasledovne:  $n = f(a)$

. Aktivačná funkcia môže rôzne priebehy. Tu je niekoľko najpoužívanejších:




Obrázok 15: Priebehy aktivačných funkcií  
Hardlim a Purelim



Obrázok 16: Priebehy aktivačných funkcií  
Logsin a Tansin

Jeden samotný neurón dokáže riešiť len triviálne úlohy. Takýto model dokázal riešiť jedine lineárne separabilné problémy. To znamená, že oblasti museli byť od seba lineárne oddelené. Pre praktické použitie musíme spájať neuróny do niekoľkých vrstiev a vytvoriť tak sieť neurónov. Prvá vrstva je tzv. vstupná vrstva, posledná vrstva je tzv. výstupná vrstva. Medzi nimi sa môže nachádzať niekoľko ďalších vrstiev, tie sa nazývajú skryté vrstvy. Jednotlivé vrstvy majú rôzny počet a je ich celkovo rôzny počet. Počet závisí od spracovanej úlohy a skúsenosti a šťastného odhadu. Na dendrity vstupnej vrstvy privádzame vstupné dáta, axony jednotlivých vstupných neurónov sú rozvedené na dendrity každého z neurónov ďalšej vrstvy. Pre vyjadrenie štruktúry celej siete, sa niekedy používa značenie typu: 5-4-4-2. To vyjadruje sieť so štyrmi vrstvami, vstupná vrstva má 5 neurónov, nasledujú dve skryté vrstvy obsahujúce po štyri neuróny a napokon výstupná vrstva s dvoma neurónmi. Je znázornená na nasledovnom obrázku: [2]



Obrázok 17: Neurónová sieť so skrytými vrstvami

### 5.2.1 Princíp fungovania neurónovej siete

Používanie a fungovanie neurónovej siete funguje nasledovne. Najprv zostavíme neurónovú sieť podľa úlohy, ktorú chceme spracovať. Vhodný počet vrstiev a neurónov vyžaduje skúsenosť alebo trochu experimentovania. Vstupom jednotlivých neurónov priradíme predvolené hodnoty váh. Práve ich hodnoty určujú ako sa bude sieť chovať. Jej použitie

pozostáva z dvoch fáz. Prvou s nich je fáza učenia. Do siete pustíme pred-pripravenú sadu vstupných dát. U nich vieme aký výsledok máme očakávať. Sieťou tieto dáta prejdú a aplikáciou predvolených váh dostaneme nejaký výsledok. Tieto zistené výsledky porovnávame so známymi výsledkami a nastavujeme hodnoty váh, aby sme dosiahli čo najvyšší stupeň ich zhody. Nastavenie hodnôt môže prebiehať manuálne alebo využitím jedného z algoritmov. Manuálne nastavovanie je použiteľné len pre jednoduché siete a malú testovaciu vzorku.

Pri samoučení používame jednu z nasledovných metód:

- Back Propagation
- Levenberg – Marquardt
- Conjugate Gradient Descent
- Quasi-Newton
- Quick Propagation
- Kohonenova adaptácia
- genetické algoritmy
- atd.

V princípe postupujeme nasledovne. Riešime problém nájdenia globálneho extrému, konkrétne globálneho minima. Tým je chyba, ktorá predstavuje rozdiel medzi známou cieľovou hodnotou premennej a vypočítanou hodnotou premennej. Chybu označujeme  $E$  (error), cieľovú hodnotu  $n$  (target) a vypočítanú aktuálnu hodnotu  $o$  (actual). Chybu vypočítame vzorcom:

$$E = (n_i - o_i)^2$$

Platí, že  $n_i$  je  $i$ -ta vypočítaná hodnota a  $o_i$  je  $i$ -ta očakávaná hodnota. Výpočet prevedieme pre všetky vstupy. Hodnota chyby sa využije pre spätné nastavenie hodnoty váh. Tento krok nazývame spätná propagácia. Proces učenia opakujeme dovtedy, kým hodnota chyby nie je nulová, resp. nedosiahne aspoň akceptovateľnú hodnotu. U neriadeného tréningu ide o identifikáciu zhluku dát s minimálnou vzdialenosťou od centra zhluku. Práve to sa využíva v ďalšom type úloh, ktoré riešime pomocou neurónových sietí. Jedná sa o tzv. zhlukovanie vstupných dát na základe spoločných rysov. Tento typ úlohy budem riešiť v ďalšej časti tejto práce práve pomocou neurónových sietí.

Po úspešnom nastavení sietí ju môžeme používať na predpoveď výsledku. Na vstup zapíšeme nové dáta, napríklad údaje o novom zákazníkovi. Neurónová sieť je naučená na

existujúcich zákazníkov a dokáže predpovedať výnosnosť, spoľahlivosť, trvácnosť nového zákazníka. [2]

## 5.2.2 Príklad použitia neurónovej siete

Ako príklad si uvedieme najjednoduchší typ neurónovej siete, tvorenej jediným neurónom, tzv. perceptron. Je to jeden neurón, ktorý má dva vstupy a jeden výstup. Našou úlohou je nastaviť váhy vstupov tak, aby neurón dával požadované výstupy. Tento príklad, je len demonštračný. Máme len veľmi obmedzenú množinu vstupov a k nim očakávané výstupy. Nastavenie siete bude ukážkové, pretože pri tak malom počte možných vstupov nie je čo predikovať ani zhľukovať. Jedná sa o triviálnu rozhodovaciu úlohu pre investovanie. Rozhodnutie je založené na podmienkach, ktoré predstavuje politické a finančné riziko –  $R_p$  a  $R_f$ . Vstup je reprezentovaný hodnotami -1 pre nevhodné podmienky a teda existujúce politické, či finančné riziko. Hodnota 1 predstavuje vhodné podmienky a neexistujúce riziko. Ak  $R_p = -1$  a  $R_f = -1$ , tak  $I = 0$  (neinvestovať), ak  $R_p = -1$  a  $R_f = 1$ , tak  $I = 1$  (invest.).

Ako aktivačnú funkciu použijeme najjednoduchší priebeh – Hardlim. Kroky sú nasledovné:

$$\text{Aktivačná funkcia: } \text{hardlim} = \begin{cases} a < 0 : n = 0 \\ a \geq 0 : n = 1 \end{cases}$$

$$\text{Inicializácia: } w = [0,5; -0,5]$$

$$\text{Prvý stav: } i = [-1, -1], o = [0]$$

$$\text{Druhý stav: } i = [1, 1], o = [1]$$

Proces učenia:

I. Vstup:  $[-1; -1]$ , váhy  $[0,5; 0,5]$ , očakávaný výsledok: 0, vypočítame chybu, nastavíme váhy

$$a' = \text{hardlim}(w' \cdot i') = (0,5 \cdot -1 + 0,5 \cdot -1) = \text{hardlim}(0) = 1$$

$$e' = (o' - a') = (0 - 1) = -1$$

$$w'' = w' + e' \cdot i' = [0,5; -0,5] + (-1) \cdot [-1, -1] = [1,5; 0,5]$$

II. Vstup:  $[1,1]$ , váhy  $[1,5; 0,5]$ , očakávaný výsledok: 1, vypočítame chybu, nastavíme váhy

$$a'' = \text{hardlim}(w'' \cdot i'') = (1,5 \cdot 1 + 0,5 \cdot 1) = \text{hardlim}(2) = 1$$

$$e'' = o'' - a'' = 1 - 1 = 0$$

$$w''' = w'' + e'' \cdot i'' = [1,5; 0,5] + 0 \cdot [1; 1] = [1,5; 0,5]$$

III. Vstup:  $[-1; -1]$ , váhy  $[1,5; 0,5]$ , očakávaný výsledok: 0, vypočítame chybu, nastavíme váhy

$$a''' = \text{hardlim}(w''' \cdot i''') = (1,5 \cdot -1 + 0,5 \cdot -1) = \text{hardlim}(-1) = 0$$

$$e''' = o''' - a''' = (0 - 0) = 0$$

$$w = w''' + e''' \cdot i''' = [1,5; 0,5] + 0 \cdot [-1; -1] = [1,5; 0,5]$$

Týmto je proces učenia ukončený. neurónovú sieť sme nastavili tak, aby správne reagovala na vstupy, a dávala nám očakávané výstupy. Môžeme pristúpiť k procesu samotnej predikcie. V tomto prípade máme ale veľmi obmedzenú množinu vstupov, takže sa vlastne jedná len o test správnosti.

Proces predikcie:

Finančné aj politické riziko existuje:  $R_f = -1$ ,  $R_p = -1$ . Chceme sa rozhodnúť pre investíciu:

$$a = \text{hardlim}(w \cdot i) = (1,5 \cdot -1 + 0,5 \cdot -1) = \text{hardlim}(-1) = 0 \Rightarrow \text{Neinvestovať}$$

Finančné aj politické riziko neexistuje:  $R_f = 1$ ,  $R_p = 1$ . Chceme sa rozhodnúť pre investíciu:

$$a = \text{hardlim}(w \cdot i) = (1,5 \cdot 1 + 0,5 \cdot 1) = \text{hardlim}(2) = 1 \Rightarrow \text{Investovať}$$

Uvedený príklad ukazuje typický príklad fungovania neurónovej siete. Pozostáva z fázy učenia a predikcie. V praxi sa používajú zložitejšie siete a riešia sa komplexnejšie problémy. Neurónové siete majú sa dať ale použiť na riešenie niekoľkých typov úloh. Medzi tie ostatné patrí napríklad zhukovanie. Jednotlivé vstupné dáta sa začlenia do príbuzných skupín, tzv. zhukov. Členovia jedného zhuku majú podobné vlastnosti. Z členstva môžeme vypožorovať zaujímavé súvislosti. [2]



## 6 Rozbor zákazníkov

Hlavným cieľom tejto diplomovej práce je zhodnotenie zákazníkov školiaceho centra. Ich rozbor pomôže zacieliť sa na najperspektívnejších klientov a nájsť príčiny neúspechu u iných. Rovnako na základe spokojnosti zákazníkov sa môžeme zamerať na tie služby, ktoré boli vysoko ohodnotené a zapracovať na tých menej úspešných. Tieto všetky kroky vedú k spoločnému cieľu, ktorým je ekonomická efektivita a finančný úspech firmy.

### 6.1 Hodnotenie spokojnosti zákazníkov


Spokojnosť zákazníkov a vysoká kvalita služieb sú hlavnými predpoklady na udržanie si stabilnej klientely a teda aj finančnej ziskovosti. Spokojnosť zákazníkov sa priebežne monitoruje a zisťuje najmä pomocou dotazníkov. Tie vyplňajú účastníci kurzu vždy pri jeho ukončení. Táto činnosť sa niektorým môže zdať otravná, prípadne zbytočná. Je pravda, že dotazníky pre spätnú väzbu vyplňujeme často a žiaľ sa často stáva, že ich obsah nepadne na úrodnú pôdu. To ale nie je prípad našej firmy. Výsledky dotazníkov sú vždy elektronicky vkladané do centrálnej databázy. V rámci ich obsahu je napríklad hodnotený aj lektor. Každý lektor má v informačnom systéme niečo ako index kvality. Ten je vypočítaný práve z jeho hodnotenia v dotazníku, ktorý vyplňajú klienti.

Podobné hodnotenie je možné vytvoriť aj pre spokojnosť klientov s jednotlivými kurzami. Táto úloha ale nie je triviálna. Zákazníci hodnotia kurzy z mnohých hľadísk, odpovedajú na väčší počet otázok a každej z nich priradzujú číselnú hodnotu. Na toto komplexné hodnotenie využijeme fuzzy logiku.

#### 6.1.1 Postup hodnotenia

Pri snahe vyhodnotiť spokojnosť zákazníkov s kurzami sme museli postupovať nasledovne. Prvým krokom bolo získanie dát z firemnej databázy a špecifikácia podmienok, za ktorých môžem údaje použiť. Ďalším krokom bolo vyčistenie a úprava dát tak, aby boli vo formáte, ktorý je možné spracovať. Nevyhnutné bolo vybrať len tie zložky dotazníkov, ktoré boli vhodné na hodnotenie. Spracúvať budeme len číselné hodnotenia. Ďalším krokom je samotné vyhodnotenie pomocou fuzzy logiky. Na tento účel bol využitý software FuzzyTech. Výsledky, ktoré nám program poskytol je napokon potrebné interpretovať. To znamená

významovo vysvetliť k akým skutočnostiam sme sa dopracovali, čo to pre našu firmu znamená a ako to môže byť prospešné pre budúci ekonomický vývoj.



Obrázok 18: Postup hodnotenia spokojnosti zákazníkov

Jednotlivé kroky si bližšie popíšeme v ďalších kapitolách, kde uvedieme aj vzorové údaje.

## 6.1.2 Získanie a úprava dát

V prvom rade bolo nutné získať vhodné dáta, ktoré bude možné ďalej analyzovať. Tento krok bol pomerne zdĺhavý, čo bolo následkom byrokratických postupov organizačnej štruktúry v podniku. Údaje boli v trochu surovej forme. Obsahovali kompletné hodnotenia, vrátane textových odpovedí a komentárov. Výnimkou neboli ani niektoré nevyplnené odpovede. Dáta mi boli dodané v tabuľke pre MS Excel.

Otazka2	Otazka3 Otazka4 Otazka5			
Počítače - služby, systémová integrace, školení ,	Počítače - ano ne			
Otazka6	Otazka7	Otazka8	Otazka9	Otazka10
Microsoft Business Solutions	Získať nové znalosti a zku			8
Otazka11	Otazka12	Otazka13	Otazka14	Otazka15
6	9	9	9	9
Otazka16	Otazka17	Otazka18	Otazka19	Otazka20
9	9	9	9	9
Otazka21	Otazka22	Otazka23	Otazka24	Otazka25
9	9	9	9	9
Otazka26	Otazka27	Otazka28	Otazka29	Otazka30
9	9	9	9	9
Otazka31	Otazka32	Otazka33	Otazka34	Otazka35
Možná ano	Nevím	Nevím	8	Velmi spokojer
Otazka36	Otazka37	Otazka38	Otazka39	Otazka40
8	8	8	8	8
InstanceCode	InstanceAffili	DateFrom	DateTo	LectorID
MOC8338	Brno	2005-10-20 00:00:00.	2005-10-21 00:00:00.	98

Tabuľka 4: Vstupné dáta pred úpravou

Vidíme, že dodané dáta bude potrebné pripraviť na budúce spracovanie. To bolo vykonané v ďalšom kroku. Hodnotenie obsahujú aj rôzne informácie osobného charakteru, odporúčania, hodnotenia slovného charakteru. Žiadna s týchto položiek nás v tomto momente nezaujíma. V procese čistenia dát sme preto vybrali len otázky s číselnými hodnoteniami. Vynechali sme

niekoľko nevhodných číselných ohodnotení. Chýbajúce hodnoty sme nahradili strednou hodnotou.

in1	in2	in3	in4	in5	in6	in7	in8	in9	in10	in11	in12	in13	in14	KodKurzu
8	6	9	9	9	9	9	9	9	9	9	9	9	9	0.45 MOC8338

*Tabuľka 5: Vstupné dáta po úprave*

### 6.1.3 Vyhodnotenie dát

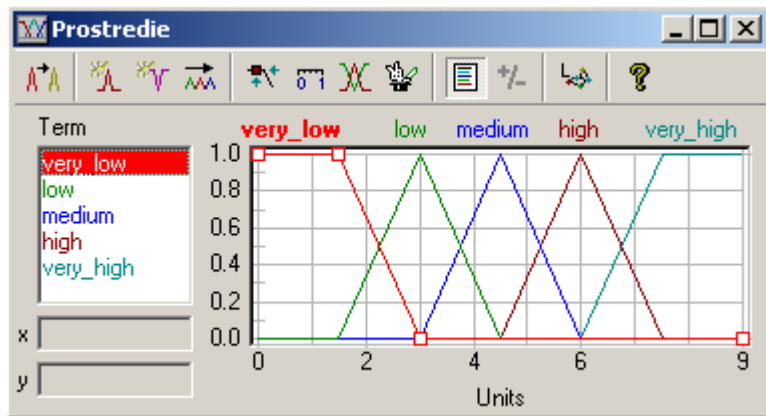
Pre vyhodnotenie kvality kurzov podľa takto zložitých kritérií sme museli siahnuť po sofistikovanej metóde. Tou je fuzzy logika. Tá je dobre použiteľná práve na vyhodnocovania na základe množstva vstupov. Bližší popis a vysvetlenie princípov fuzzy logiky sa nachádza v začiatku tohto dokumentu, v kapitole 5.1.

Na účely spracovania bol použitý software FuzzyTECH od spoločnosti INOFRM GmbH. Ten je možné stiahnuť z webových stránok spoločnosti. Voľne dostupná je len demo verzia, ktorá ale postačuje pre naše potreby. Výhodou tohto SW je intuitívne grafické rozhranie, sprievodcovia pre vytvorenie modelu a pravidiel a taktiež aj možnosť dávkového spracovania veľkého množstva dát.

Pri práci so SW FuzzyTECH musíme najprv vytvoriť model pre spracovanie. Ten pozostáva zo vstupov, blokov s pravidlami a z výstupov. Každý vstup musíme pomenovať, zvoliť mu rozsah vstupných hodnôt a počet stupňov pre fuzzyfikáciu. V našom prípade máme celkovo 14 vstupov. Každý vstup nadobúda hodnoty od 1 do 9. Pre všetky vstupy sme definovali možné členstvo v piatich fuzzy množinách. Tie sme označili hodnotami:

- very\_low
- low
- medium
- high
- very\_high

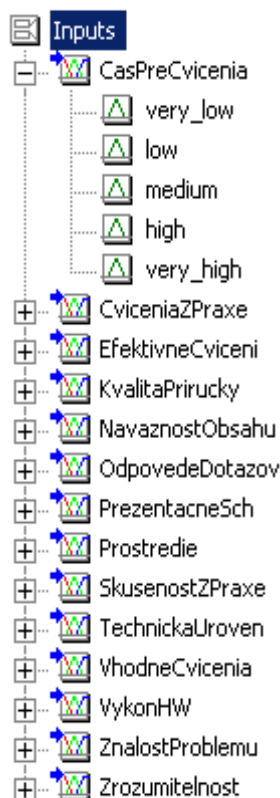
Zároveň sme im priradili členské funkcie. Tie majú priebehy tvaru  $Z$  pre prvú množinu a priebeh tvaru  $S$  pre poslednú množinu. Vo všetkých ostatných prípadoch sa jedná o priebehy tvaru  $\Lambda$ .



Obrázok 19: Fuzzyfikácia vstupných hodnôt

Analogicky sme postupovali aj pre ostatné vstupy. Keďže celkový počet vstupov je pomerne veľký, tak sme ich rozdelili do štyroch kategórií. To je vhodné pre prehľadnosť, zodpovedá to sekciám na dotazníku, ale hlavne to znižuje celkový počet pravidiel, ktoré musíme ďalej definovať.

- Učebňa
  - kvalita prostredia
  - výkon HW a SW
- Lektor
  - znalosť problematiky
  - odpovede na dotazy
  - skúsenosť v praxi
  - prezentačné schopnosti
- Obsah kurzu
  - zrozumiteľnosť obsahu
  - náväznosť obsahu kurzu
  - technická úroveň obsahu
  - jazyková kvalita príručky
- Cvičenia
  - vhodné pre upevnenie znalostí
  - v súlade s reálnou praxou
  - efektívne cvičenia
  - dostatok času na cvičenia



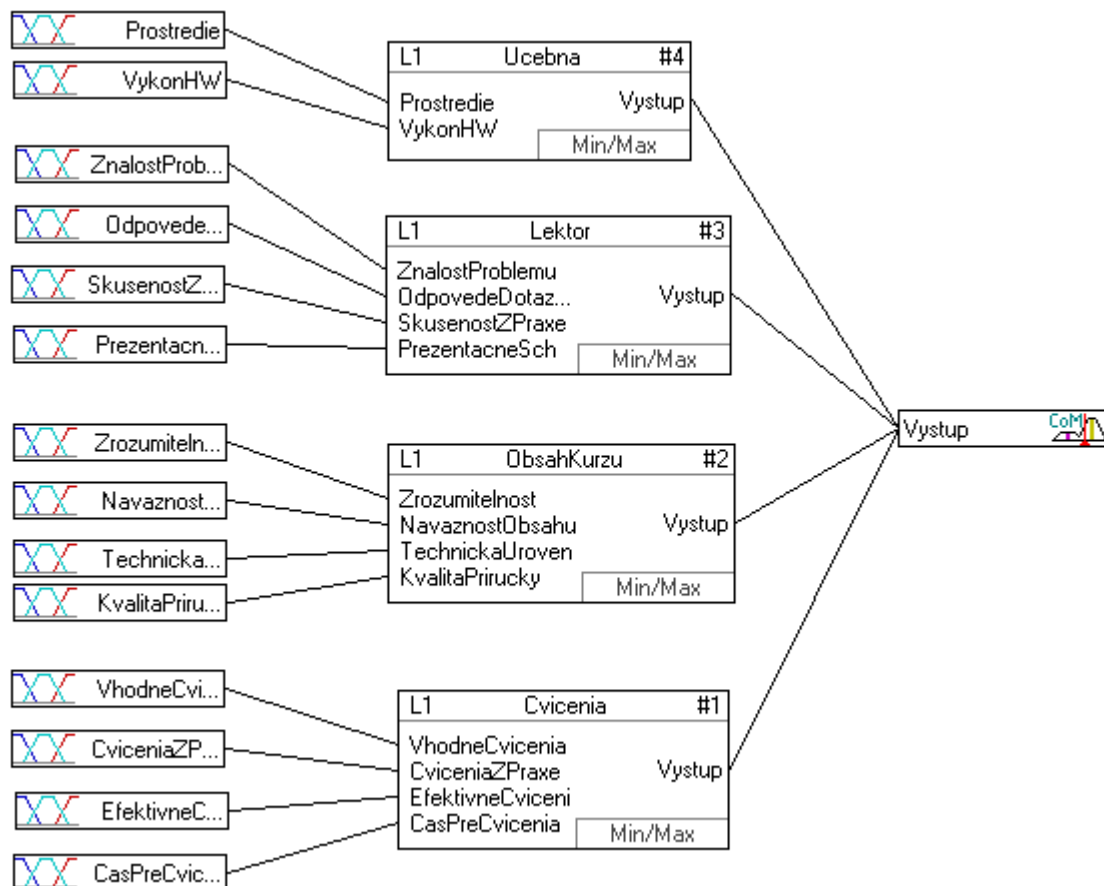
Obrázok 20:

Definovanie vstupov

V ďalšom kroku bolo nevyhnutné zostrojiť celkový fuzzy model. Ten pozostáva zo vstupov, blokov s pravidlami a výstupov. V našom prípade sme definovali celkovo 14 vstupov, 4 bloky s pravidlami a jeden výstup. Vstupné hodnoty majú hodnoty v rozpätí 1 až 9 a tie sú následne transformované do 5 stupňov. Jednotlivé vstupy sú po fuzzyfikácii privádzané do blokov s pravidlami. Pomocou týchto pravidiel nastáva fuzzy interferencia. Tieto medzivýsledky sa nakoniec privedú do časti výstupu. Tam sa zoskupia, vyhodnotia a nastáva de-fuzzyfikácia. To znamená, že miesto príslušnosti do jednotlivých fuzzy množín dostávame číselný index kvality. Ten je opäť v rozpätí od 1 do 9.

Na obrázku vidíme celkový model pre fuzzy výpočet hodnotenia spokojnosti zákazníkov. Okrem špecifikácie jednotlivých vstupov, výstupov, blokov pravidiel a ich prepojeniami, sme museli definovať aj jednotlivé pravidlá. Každý z blokov pravidiel musí obsahovať zoznam pravidiel. Pravidlá majú tvar:

*IF vstup=low AND vstup2=medium AND ... AND vstup14=very\_high THEN vystup=medium*



Obrázok 21: Fuzzy model

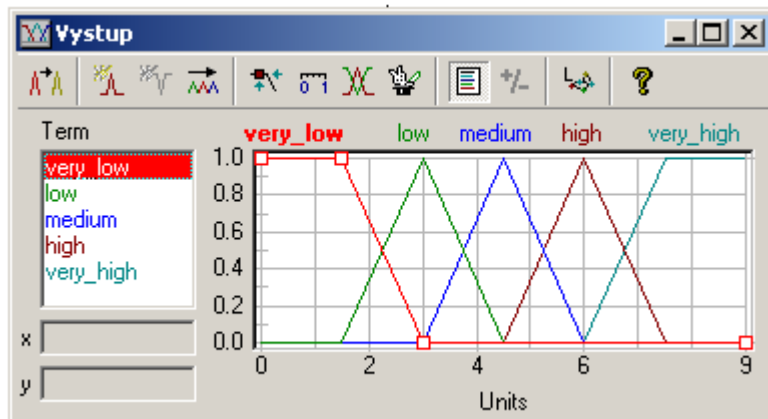
Tieto pravidlá musíme definovať tak, aby pokryli všetky možné kombinácie vstupov. Potrebný počet si jednoducho vypočítame. Máme  $N$  vstupov, ktoré nadobúdajú 5 možných hodnôt. Teda počet pravidiel je  $5^N$ . Počet vstupov pre prvý blok je 2 a pre každý ďalší 4. Teda pre prvý blok potrebujeme 25, pre druhý blok 625, pre tretí blok 625 pravidiel. Spolu je to 1900 pravidiel.

Práve pre tento prípad, kde musíme definovať veľké množstvo pravidiel, sa hodí program FuzzyTECH. Nájdeme v ňom napríklad aj sprievodcu pre vytváranie pravidiel. Ten nám sám vygeneruje zoznam pravidiel, pre všetky možné kombinácie vstupov. Príklad pre prvý blok vidíme na obrázku č.22.

#	IF		THEN	
	Prostredie	VykonH/W	DoS	Vystup
1	very_low	very_low	1.00	very_low
2	very_low	low	1.00	very_low
3	very_low	medium	1.00	low
4	very_low	high	1.00	low
5	very_low	very_high	1.00	medium
6	low	very_low	1.00	very_low
7	low	low	1.00	low
8	low	medium	1.00	low
9	low	high	1.00	medium
10	low	very_high	1.00	high
11	medium	very_low	1.00	low
12	medium	low	1.00	low
13	medium	medium	1.00	medium
14	medium	high	1.00	high
15	medium	very_high	1.00	high
16	high	very_low	1.00	low
17	high	low	1.00	medium
18	high	medium	1.00	high
19	high	high	1.00	high
20	high	very_high	1.00	very_high
21	very_high	very_low	1.00	medium
22	very_high	low	1.00	high
23	very_high	medium	1.00	high
24	very_high	high	1.00	very_high
25	very_high	very_high	1.00	very_high
26				

Obrázok 22: Pravidlá pre prvý blok pravidiel

Posledná časť modelu vyhodnotí vstupy zo všetkých štyroch blokov pravidiel. Na základe štyroch príslušností do fuzzy množín vykoná de-fuzzyfikáciu. Teda výslednej hodnote priradí číselný index. Ten je znovu z rozsahu 0 až 9. Tým získame celkové výsledné hodnotenie spokojnosti zákazníkov s jednotlivými kurzami. Aj vo výstupnom bloku máme možnosť definovať členské funkcie pre jednotlivé vstupy z blokov pravidiel. Ich priebehy sú analogické ako pre vstupy. Majú priebehy tvaru *Z* pre vstup z prvého bloku a priebeh tvaru *S* pre vstup z posledného bloku. Vo všetkých ostatných prípadoch sa jedná o priebehy tvaru *A*. V predvolenom nastavení malí posledne spomínaný priebeh všetky vstupy zo všetkých blokov. Vo výsledku sme však dostávali nízke výsledné hodnoty aj pre kurzy, ktoré mali všetky atribúty hodnotené výnimočne vysoko. Aby výsledky lepšie zodpovedali skutočnosti, tak sme zvolili priebehy *S* a *Z*. Pre lepšie pochopenie celého procesu spracovania je uvedený názorný príklad pre jeden vstup.



Obrázok 23: Členské funkcie pre výpočet výstupu

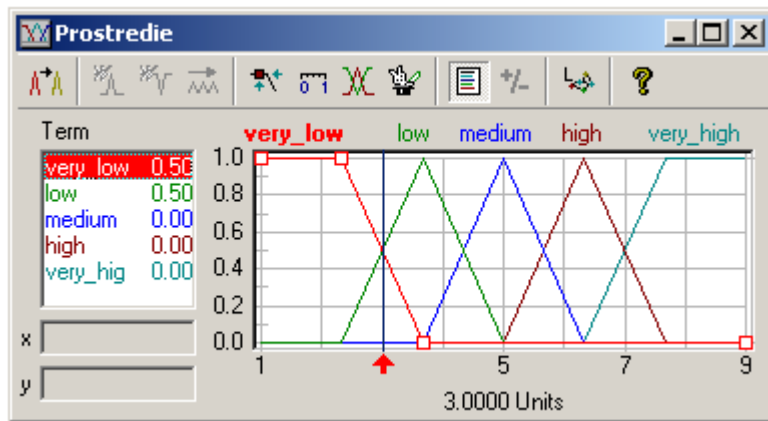
### 6.1.4 Príklad

Ako príklad uvidíme spracovanie hodnotenia jedného kurzu. Vyplnené hodnoty z dotazníku

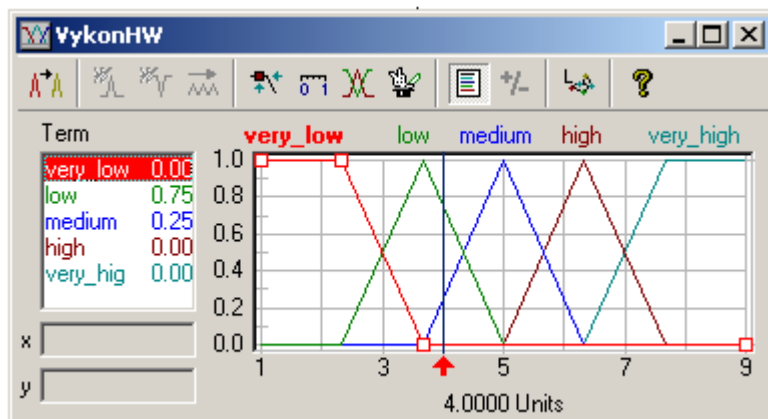
- Učebňa
  - kvalita prostredia = 3
  - výkon HW a SW = 4
- Lektor
  - znalosť problematiky = 6
  - odpovede na dotazy = 6
  - skúsenosť v praxi = 6
  - prezentačné schopnosti = 6
- Obsah kurzu
  - zrozumiteľnosť obsahu = 4
  - náväznosť obsahu kurzu = 5
  - technická úroveň obsahu = 3
  - jazyková kvalita príručky = 8
- Cvičenia
  - vhodné pre upevnenie znalostí = 2
  - v súlade s reálnou praxou = 3
  - efektívne cvičenia = 2
  - dostatok času na cvičenia = 2



Najprv zistíme členstvo vstupných hodnôt v jednotlivých fuzzy množinách. Pre hodnotení prostredia bola zadaná hodnota 3. Aplikáciou členských funkcií zistíme, že hodnota spadá z polovice do množiny *very\_low* a z polovice do množiny *low*. Pri hodnotení výkonu HW bola zadaná hodnota 4. Tá spadá z troch štvrtín do množiny *low* a štvrtinou do množiny *medium*.



Obrázok 24: Stupeň príslušnosti prvého vstupu



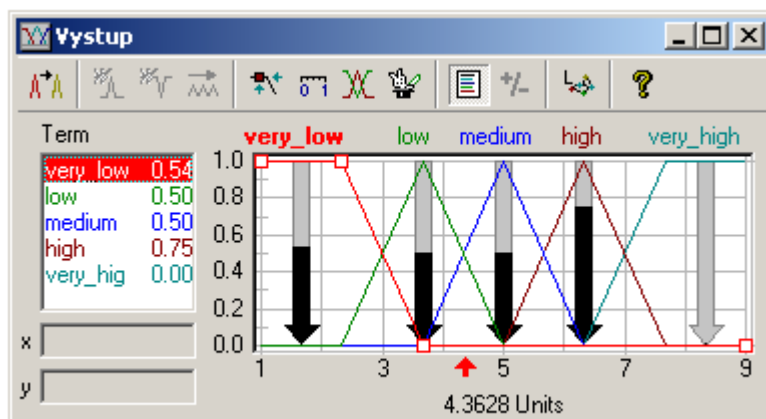
Obrázok 25: Stupeň príslušnosti druhého vstupu

Na základe členstva v množinách toto vyhodnotíme v bloku s pravidlami. V bloku nájdeme pravidlá pre všetky možné kombinácie. Použijeme ale len tie pravidlá, ktoré zodpovedajú členstvu vstupov vo fuzzy množinách. Členstvo je relatívne a prvok môže byť členom viacerých množín s rôznym stupňom príslušnosti. To sa stalo aj našom prípade a preto je použiteľných niekoľko pravidiel. Podľa stupňa príslušnosti do fuzzy množín, je v tabuľke z vyfarbený čierny rámček pri každom pravidle. Môžeme to chápať ako mieru zhody s daným pravidlom. Obdobne by sme postupovali aj pri vyhodnocovaní ďalších vstupov a ďalších blokov s pravidlami. Z takto vyhodnotených pravidiel môžeme vybrať buď to s najvyšším stupňom zhody alebo vypočítať tzv. ohraničenú sumu. Výsledok putuje do výstupného bloku.

Spreadsheet Rule Editor - Ucebna				
#	IF		THEN	
	Prostredie	VykonHW	DoS	Vystup
1	very_low	very_low	1.00	very_low
2	very_low	low	1.00	very_low
3	very_low	medium	1.00	low
4	very_low	high	1.00	low
5	very_low	very_high	1.00	medium
6	low	very_low	1.00	very_low
7	low	low	1.00	low
8	low	medium	1.00	low
9	low	high	1.00	medium

Obrázok 26: Stupeň zhody s pravidlami

Výstupný blok má za úlohu spracovať štyri vstupy z blokov pravidiel. Jednotlivé bloky poskytujú členstvo vo fuzzy množinách. V našom prípade výstup z každého z blokov spadá do rozdielnej množiny. Máme tu vždy jedenkrát zastúpenú množinu *very\_low*, *low*, *medium*, *high*. Vyhodnocovací výstupný blok zobrazí získané členstvá v množinách šípkami. Stupeň členstva je vyjadrený čiernou farbou. V našom prípade vidíme čiastočnú príslušnosť do každej zo získaných množín. Výstupný blok vypočíta vážený priemer, ktorý leží na rozmedzí všetkých medzihodnôt. Takto získame finálny číselný index. Vo vzorovom prípade je to hodnota 4,36. Tomuto procesu hovoríme de-fuzzyfikácia. Podobne postupujeme pri vyhodnocovaní všetkých skúmaných hodnôt. Spracovanie ale prebieha dávkovo a nemusíme kontrolovať jednotlivé medzikroky. Výstup pre všetky skúmané položky nájdeme vo výstupnej tabuľke. Tú možno ďalej spracovať v tabuľkovom editore typu MS Excel.



Obrázok 27: Výstup

## 6.1.5 Interpretácia výsledkov

Vo výstupnej tabuľke nájdeme zoznam všetkých hodnotení kurzov od všetkých zákazníkov, ktorí dané školenie absolvovali. Podstatný fakt je výsledné skóre. To predstavuje finálny index kvality kurzu. Pre zmysluplnú interpretáciu bolo nevyhnutné vykonať niekoľko úprav. Jednotlivé kurzy boli hodnotené rádovo desiatkami až stovkami účastníkmi. Preto sme zoskupili všetky hodnotenia pre daný kurz a vypočítali priemerné skóre. Napokon sme kurzy zoradili od najlepšieho po najhorší. Pre štatistickú korektnosť sme vylúčili kurzy, ktoré boli hodnotené menej ako tri krát. Takéto obzvlášť málo frekventované školenia mali často extrémne hodnotenia, ktoré nemali vypovedajúcu hodnotu. Kompletná tabuľka s výsledkami sa nachádza v prílohe. V nasledovných tabuľkách vidíme zoznam 10 najlepšie hodnotených a 10 najhoršie hodnotených kurzov.

### KódKurzu Skóre Názov

MOC2159	8,25	Deploying and Managing Microsoft ISA Server 2000
MOC8333	8,25	Microsoft Business Solutions - Axapta 3.0 Sales
MOC8911	8,25	Installation and Deployment in Microsoft Dynamics CRM 4.0
MOC8365	8,1	Microsoft Navision 4.0 Service Management
MOC4357	8,09	Windows Server 2003 R2 - správa datových úložísk
MOC8358	8,07	Microsoft Navision 4.0 Resources and Jobs
MOC8401	8,07	Microsoft Navision 4.0 Development II
MOC2505	8,06	Deploying Microsoft Office XP
MOC2557	8,06	Tvorba COM+ aplikácií pomocou Microsoft .NET Enterprise Service
MOC6426	8,04	Windows Server 2008 - správa PKI, ADFS a RMS

*Tabuľka 6: 10 najlepších kurzov*

MOC8625	6,75	Microsoft Dynamics AX 4.0 Trade & Logistics I
GOC5115	6,73	Windows Vista – nasazení a správa
GOC2014	6,71	Přizpůsobení a programování Windows Sharepoint Services 3.0
MOC5178	6,68	Office Communications Server 2007 - nasazení a správa hlasových konferenčních s.
GOC2559	6,62	Visual Basic .NET - základy programování
MOC8355	6,62	Axapta® 3.0 Installation and Configuration II
MOC5177	6,53	Configuring Microsoft Windows Vista Mobile Computing
GOC352	6,5	Windows Communication Foundation
GOC2310	6,45	Úvod do vývoje ASP.NET webových aplikací
MOC8330	6,4	Axapta® 3.0 Financial Series I
MOC2788	6,37	Microsoft SQL Server 2005 - návrh řešení s vysokou dostupností
MOC3201	6,27	Developing Microsoft ASP.NET 2.0 Web Applications
GOC2541	5,96	Tvorba databázových aplikací pomocí ADO.NET

*Tabuľka 7: 10 najhorších kurzov*


## 6.2 Klasifikácia zákazníkov

Školiace centrum GOPAS má , tak ako väčšina veľkých firiem, veľké množstvo zákazníkov. V tomto prípade sa nebavíme o koncových účastníkov školení ale o firmách, ktoré účastníkov zamestnávajú. Pre efektívne fungovanie firmy a ekonomickú výnosnosť jej činnosti je nutné dobre poznať svojich zákazníkov. Ich dôkladné preskúmanie pomáha udržať si tých, ktorí sú pre nás najviac perspektívni, ale aj zapracovať na odstraňovaní príčin nespokojnosti tých ostatných.

Klasifikovať zákazníkov môžeme z rôznych hľadísk a rôznymi metódami. Jednou z nich je známa marketingová segmentácia. V marketingovej segmentácii ale rozdeľujeme všetkých potenciálnych zákazníkov podľa niekoľkých faktorov do skupín – segmentov. Následne sa zameriame len na tých, ktorí sú pre nás zaujímaví. Tento postup je vhodný napríklad pri prieskume trhu. Typicky pred uvedením nového produktu na trh, alebo pred preniknutím na nové trhy.

Trochu odlišný je prístup, ktorý sme si zvolili pre naše potreby my. V tomto prípade už máme skupinu zákazníkov, ktorí v minulosti aspoň raz využili naše služby. O zákazníkoch máme informácie, ktoré nám poskytli vyplnením dotazníku po ukončení školenia. Na základe týchto údajov by sme ich radi klasifikovali. Takáto klasifikácia sa nazýva zhlukovanie, alebo clustering. Všetkých zákazníkov rozdelíme do niekoľkých skupín, zhlukov, podľa podobných vlastností. To dosiahneme tak, na základe jednej alebo viac charakteristík nájdeme niekoľko skupín, zhlukov, ktoré sú seba navzájom blízke. Každý zhluk má svoj stred, centrum. Príslušnosť do daného zhluku sa posudzuje podľa vzdialenosti prvku od centra zhluku. Prvok patrí do toho zhluku, ku ktorého centru je najbližšie.

Ako príklad môžeme uviesť geografické rozmiestnenie odberateľov nejakého tovaru, či služby. Našou úlohou je umiestniť niekoľko predajní tak, aby k nim mali zákazníci čo najbližšie. Využijeme na to zhlukovanie, zhlukovať budeme na základe dvoch parametrov – zemepisnej šírky a zemepisnej dĺžky. Ako vstup nám poslúži zoznam geografických lokácií odberateľov. Výstupom bude ich rozdelenie do niekoľkých zhlukov. Členovia zhluku majú k sebe navzájom vždy veľmi blízko. Každý zhluk má takzvané centrum. Práve polohy centier zhluku nám v tomto prípade indikujú, kam by sme mali postaviť naše predajne, resp. sklady. Vzorový výstup je zobrazený na obrázku č.28. Zákazníci sú označení červene a polohy pre predajne čierne. Na dosiahnutie tohto výpočtu použijeme neurónové siete – tzv. Hochfeldovú neurónovú sieť.



Obrázok 28: Ukážka zhľukovania

### 6.2.1 Hodnotiace kritériá zákazníkov

Našich zákazníkov hodnotíme podľa niekoľkých kritérií súčasne. Informácie o nich sme získali z dotazníkov, ktoré vyplňajú po skončení školenia. Kritéria sú nasledovné:

- veľkosť firmy – približne reprezentovaná počtom počítačov
- Skúsenosti zamestnancov v obore – udávané v počte rokov
- Zameranie zamestnancov – rozdelenie do niekoľkých kategórií
- Využitie znalostí získaných na kurze
- Zvýšenie pracovného výkonu ako dôsledok absolvovaného školenia.

Jednotlivé kritéria môžu nadobúdať hodnoty z nasledovných intervalov:

- počet počítačov: 1-4, 5-24, 25 – 49, 50 – 249, 250 – 499, 500 – 749, 750 – 2499, 2500 – 12 499, 12500 – 24999, 25000 a viac.
- Skúsenosti v obore: menej než rok, 1 – 3, 3 – 5, 5 – 7, 7 – 10, 10 rokov a viac
- Pozícia zamestnanca : užívateľ, vývojár, IT špecialista, obchodník, manažér
- Využitie znalostí: 0%, 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90%, 100%
- Zvýšenie výkonu: 0%, 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90%, 100%

Našou úlohou je vyhodnotiť zákazníkov na základe týchto piatich kritérií. Hodnotenie prebehne formou zhľukovania. Tým rozdelíme zákazníkov do niekoľko skupín so spoločnými črtami. Radi by sme získali aj charakteristiky jednotlivých skupín a ich vzťah k ostatným skupinám. Na tento účel môžeme použiť niekoľko metód a nástrojov. V tomto prípade sme použili tzv. clustering pomocou neurónových sietí. Popis ich fungovania je uvedený v kapitole č.2.2. Najčastejší spôsob ich využitia je učenie sa a následná predikcia. My sme ich využili iný z ich možných účelov. Tým je práve zhľukovanie

## 6.2.2 Úprava vstupných dát

Vstupné charakteristiky sme najprv museli získať. Z dôvodu diskretnosti a ochrany údajov o našich zákazníkoch nebudem ďalej v práci uvádzať mená a názvy organizácií. Namiesto toho sú všade uvádzané len pseudonymy. Týmto sa zároveň zbavujeme nutnosti utajenia diplomovej práce, čo často prináša viac komplikácií než úžitku. V tabuľke č. 8 vidíme vstupné údaje v surovej podobe.

Otazka37	Otazka38	Otazka39	Otazka40	Otazka42	Otazka43	Otazka44	Název
Manažer	3 až 5 rokov	750 - 2.499 PC	80%	20%	10% ANO		aaa
Vývojár	více než 10 rokov	50 - 249 PC	10%	30%	20% NE		bbb
Jiný, prosím	více než 10 rokov	50 - 249 PC	60%	60%	50% ANO		ccc
Vývojár	Méně než 1 rok	750 - 2.499 PC	70%	40%	20% ANO		ddd
Manažer	7 až 10 rokov	25 - 49 PC	20%	20%	20% ANO		eee

*Tabuľka 8: Vstupné údaje pre zhľukovanie*

Dáta v tomto tvare ale nie sú priamo použiteľné pre rozbor. Museli sme ich preto upraviť. Vybrali sme len tie stĺpce, ktoré boli vhodné pre spracovanie. Jedná sa o počet počítačov, počet rokov skúseností v obore, zameranie zamestnancov, využitie získaných znalostí a zvýšenie výkonu po školení. Pri úprave údajov sme vykonali nasledovné operácie. V množstve počítačov sme vybrali strednú hodnotu z každého intervalu. V rokoch skúseností sme tiež vybrali strednú hodnotu z intervalu. Pri využití znalostí a zvýšení výkonu sme percentuálnu hodnotu previedli na index v rozsahu 0 až 1. Zameranie zamestnancov je:

- užívateľ = 1
- programátor = 2
- IT špecialista = 3
- konzultant = 4
- obchodník = 5
- manažér = 6

Názefirmy	PočetPC	Rokyúseností	Zameraniezamestnancov	Využitieznaostí	Zvýšenievýkonu
aaa		1	3	0,00	0,00
bbb		1	3	0,50	0,50
ccc	1625	4	6	0,80	0,20
ddd	150	10	2	0,10	0,30
eee	150	10	4	0,60	0,60

Tabuľka 9: Vstupné dáta po úprave

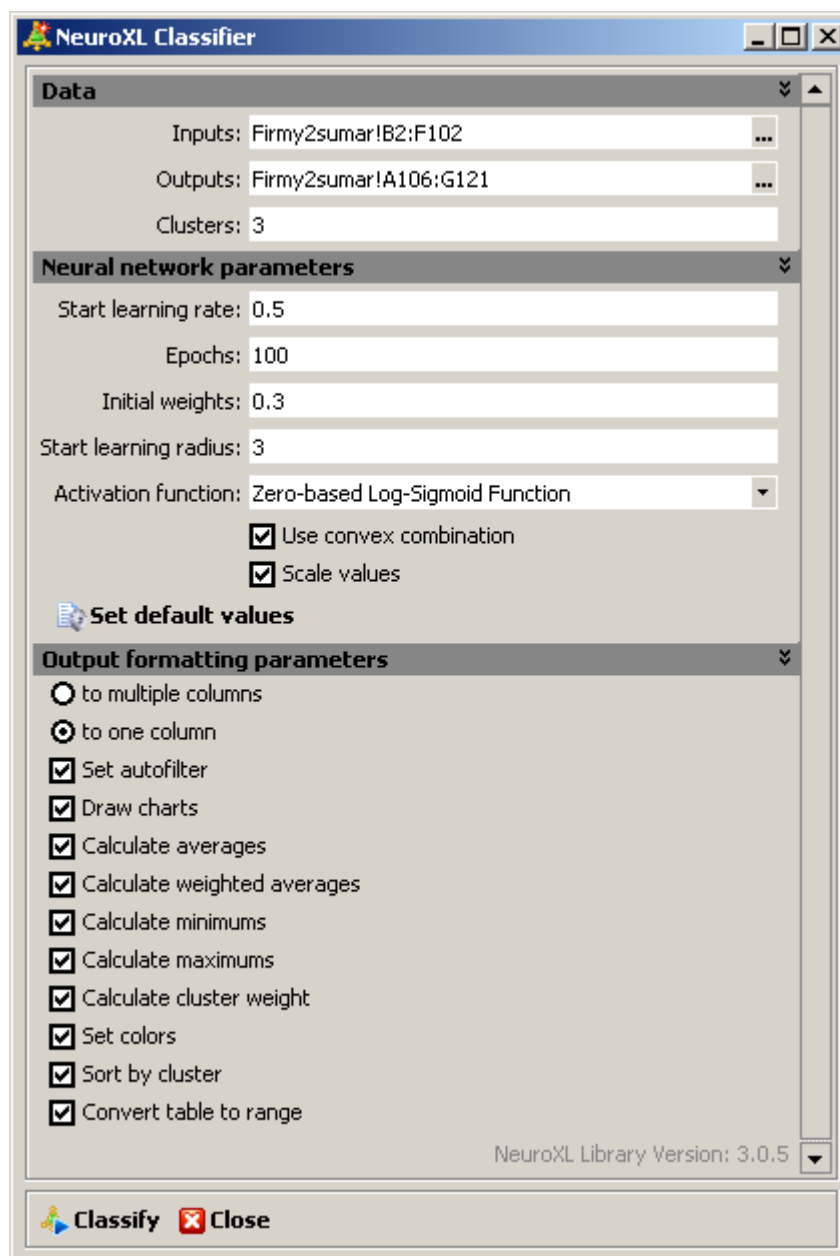
### 6.2.3 Spracovanie dát

Na spracovanie údajov sme použili software NeuroXL Classifier od firmy menom OLSOFT LLC. Ten je dostupný z webových stránok spoločnosti. Pre naše účely postačí demo verzia, ktorá je plne funkčná po dobu niekoľko dní. Tento program funguje ako prídavný modul do MS Excel. Je Preto jednoduché, rýchle a intuitívne použiteľný. Po inštalácii sa objaví v MS Excel v menu Add-ins položka ClassifierXL. Po jeho spustení uvidíme nasledovnú obrazovku zobrazenú na obrázku č. 29. Použitie je triviálne. V časti *Inputs* vyberieme bunky, ktorých obsah chceme klasifikovať. Musíme si ale dať pozor na to, aby vo výbere neboli zahrnuté hlavičky a popisy. Rovnako je požadované aby všetky hodnoty boli číselné. Nečíselné hodnoty nemôžu byť spracované a spôsobia chybu programu. Ďalej pokračujeme časťou *Output* kde špecifikujeme bunky pre zobrazenie výstupu. V položke *Clusters* volíme do koľkých zhlukov chceme dáta rozdeliť. Vyberieme tri zhluky.

V druhej sekcii môžeme zvoliť vlastnosti neurónovej siete. Medzi možnosťami nájdeme štandardne tvar aktivačnej funkcie, ktorý je predvolene Log Sigmoid. Nasleduje možnosť nastaviť počet epoch, predvolene 100, alebo úvodné váhy pre vstupy neurónov. Predvolená hodnota je 0,5.

V tretej sekcii nastavujeme tvar a parametre výstupu. Veľkou výhodou programu NeuroXL Classifier je jeho schopnosť generovať grafické výstupy, ktoré sú zrozumiteľné a ihneď použiteľné. Na výber máme veľa rad možností, medzi nimi aj: usporiadať a farebne rozlíšiť jednotlivé zhluky. Vypočítať stred, maximum, minimum a vážený priemer zhliku. Nesmieme zabudnúť ani na možnosť vykresliť grafy.

Menšou nevýhodou tohto softwaru môže byť fakt, že striktne vyžaduje produkt MS Excel. Nepostačuje prítomnosť voľne dostupnej čítačky MS Excel Reader, ani prítomnosť voľne dostupného OpenOffice. Napriek tomu patrí NeuroXL Classifier medzi najlacnejšie produkty na trhu, v rámci svojej kategórie. Plná verzia je dostupná za menej ako 100 amerických dolárov, čo je pri súčasnom kurze výhodná ponuka.



Obrázok 29: Použitie NeuroXL Classifier

## 6.2.4 Vyhodnotenie dát

Po spracovaní dostaneme na výstupe výstupné dáta. Tie musíme vyhodnotiť a interpretovať. V tabuľke č. 10 vidíme číselné charakteristiky jednotlivých zhlukov. Pre každý z piatich ukazateľov je vypočítaný priemer, vážený priemer, minimálne a maximálne hodnoty. Vážený priemer je vzájomné percentuálne porovnanie medzi zhlukmi. Napríklad ak pri hodnote zvýšenia výkonu vidíme -25%, tak to neznamená, že sa výkon zvýši, ale že je -25% pod priemernou hodnotou pre všetky zhluky. Pre zvýšenie výkonu je to od indexu 0,24 do indexu




0,46 zvýšenia. Podobná skutočnosť platí aj pre využitie znalostí. Záporné percentuálne hodnoty sú len relatívnym vyjadrením ku ostatným zhlukom. Vidíme, že využitie znalostí sa pohybuje od indexu 0,26 po 0,45. Inými slovami, klienti využívajú získané znalosti v rozmedzí 26 až 45 % svojho pracovného času. V priemere je to zhruba 35 percent. Vo vzťahu k tomuto priemeru je preto index využitia znalostí 0,26 pod priemerom. To je v tabuľke vyznačené zápornou hodnotou.

	Počet PC	Roky skúseností	Zameranie zam.	Využitie znalostí	Zvýšenie výkonu
<b>Zhluk 1 priemer</b>	1886,26	8,35	3,08	0,26	0,24
<b>Zhluk 2 priemer</b>	1058,22	5,65	2,96	0,45	0,46
<b>Zhluk 3 priemer</b>	102,38	2,06	3,55	0,27	0,25
<b>Z1 vážený priemer</b>	60,30%	40,84%	-2,07%	-21,07%	-26,04%
<b>Z2 vážený priemer</b>	-10,07%	-4,69%	-5,76%	35,47%	43,20%
<b>Z3 vážený priemer</b>	-91,30%	-65,27%	12,95%	-19,50%	-23,08%
<b>Zhluk 1 minimum</b>		5,95		0	0
<b>Zhluk 2 minimum</b>	15	1	1,5	0,1	0,27
<b>Zhluk 3 minimum</b>		1	1	0	0
<b>Zhluk 1 maximum</b>	25000	10	6	0,7	0,5
<b>Zhluk 2 maximum</b>	22562,5	10	6	0,75	0,7
<b>Zhluk 3 maximum</b>	380	4,92	6	0,7	0,6

*Tabuľka 10: Číselné charakteristiky zhlukov*

V tabuľke č. 10 vidíme aj ďalšie podrobné číselné charakteristiky. Zaujímavé sú napríklad priemerné hodnoty zhlukov pre jednotlivé vlastností. Tieto priemery sú blízke centráam zhlukov. Pomôžu nám predstaviť si okolo ktorej hodnoty sa pohybujú hodnoty všetkých firiem v danom zhluku. Pre celkovú predstavu si môžeme všimnúť aj minimálne a maximálne hodnoty. Tie patria pre extrémne prípady, ktoré sú väčšinou najďalej od centier zhlukov. Ale aj tieto krajné prípady musíme vždy zaradiť do jedného konkrétneho zhluku. Pozornému oku určite neujde fakt, že v niektorých prípadoch nie je definovaná minimálna hodnota. Dôvodom je nevyplnené políčko v dotazníku. Preto boli niektoré vstupné a teda aj výstupné hodnoty prázdne.

Na obrázku č. 32 môžeme vidieť distribúciu firiem v rámci jednotlivých zhlukov. Je zrejmé že firmy sú do nich zaradené nerovnomerne. Najviac firiem patrí do prvého zhluku, celkovo približne 40 %. Do druhého zhluku spadá asi 37% firiem. Posledná skupina je najmenšia. Je tvorená približne 23 %. zo všetkých skúmaných firiem, Celkový počet firiem, ktoré sú v tejto úlohe hodnotené je 101 spoločností. Jedno percento predstavuje približne jednu firmu.




Obrázok 30:

*Zhlukovanie - závislosť skúseností a využitia znalostí*


Pre predstavu a úplnosť ešte uvedieme dvojrozmerné zobrazenie do zhlukov. V našom hodnotení zhlukujeme firmy na základe 5 charakteristík. O členstve v jednotlivých zhlukoch preto rozhoduje 5 ukazateľov. Pre grafické zobrazenie rozčlenenia jednotlivých firiem by sme museli siahnuť po 5 dimenzionálnom grafe. To prakticky nie je možné. Ukážkovo uvádzam aspoň 2D graf, ktorý ukazuje distribúciu medzi jednotlivé zhluky na základe 2 parametrov. Toto zobrazenie sme dodatočne vytvorili a vychádza z rozdelenia na základe 5 charakteristík. Preto nie je úplne presné a smerodajné. Poslúži aspoň pre lepšiu predstavu hlavného princípu zhlučovania – clusteringu. Na obrázku č. 30 vidíme zobrazenie závislosti využitia získaných znalostí v závislosti na skúsenostiach zamestnancov. Jednotlivé firmy sú vyznačené modrou bodkou. Centrá zhlukov zasa červeným kosoštvorcom. Pre zvýraznenie

sú okolo centier načrtnuté elipsy. Tie orientačne ukazujú, ktoré firmy spadajú do ktorého zhuku. Elipsy nie sú ostrými hranicami zhukov. Len vizuálne zvýrazňujú najväčšiu skupinu spadajúcu do zhuku.



*Obrázok 31: Zhlukovanie - závislosť zamerania a využitia znalostí*

Na obrázku č. 31 vidíme grafické zobrazenie zhukovania. Jedná sa o rozdelenie pre závislosť využívania získaných informácií a zamerania zamestnancov. Platí to isté, čo v pre predchádzajúce zobrazenie. Opäť pripomínam, že pod číselnými hodnotami zamerania zamestnancov sa skrývajú typické pozície. Pozície bližšie k nule sú užívateľské, pozície v strede poľa sú technické pozície a najvyššie hodnoty predstavujú pozície manažérske. Distribúciu na základe všetkých piatich charakteristík súčasne nedokážeme zobrazit'. Môžeme ale vykresliť graf, ktorý navzájom porovná stredné hodnoty jednotlivých zhukov podľa všetkých parametrov. Takýto graf nájdeme na obrázku č. 33. Je to asi najlepšia zobrazovacia pomôcka pre tento prípad.




*Obrázok 32: Rozdelenie firiem do jednotlivých zhhlukov*

Najzaujímavejší je asi obrázok č. 33, kde sú zobrazené profily jednotlivých zhhlukov. Tu vidíme charakteristiky jednotlivých skupín. Z týchto informácií môžeme vypožorovať zaujímavé skutočnosti.

Zhluk číslo 1 je tvorený firmami, ktorý majú veľmi veľké množstvo počítačov, a veľmi skúsených zamestnancov. Tí majú skôr technické pozície ako správcovia sietí alebo programátori. Využitie získaných znalostí aj zvýšenie výkonu je nižšie.

Zhluk číslo 2 pozostáva zo spoločností, ktoré majú stredne veľký počet počítačov a stredne skúsených zamestnancov. Tí sú opäť prevažne na technických pozíciách. Veľmi zaujímavé je ich nadpriemerne využívanie získaných znalostí a následne nadpriemerné zvyšovanie pracovných výkonov.

Vidíme, že najmenšie vzájomné odchýlky sú u zamerania zamestnancov. To je dané jednak malým rozmedzím vstupných hodnôt a tiež podobnosťou zákazníkov, na ktorých sú školenia zamerané. Najväčšie odchýlky badáme v počte počítačov vo firmách. To je dané jednak veľkým rozpätím hodnôt vstupných dát ale aj rôznorodosťou našich zákazníkov. Na školenia totiž chodia zamestnanci veľkých korporácií, stredných firiem, malých firiem a výnimočne aj jednotlivci.



Obrázok 33: Profily zhlukov

V prípade poslednej skupiny firiem sa jedná o podniky s menším počtom počítačov. Tie majú málo skúsených zamestnancov. Tí sú buď na technických alebo manažérskych pozíciách. Využitie informácií a zvýšenie pracovných výkonov následkom školenia je pomerne nízke. Znovu ale musím upozorniť, že sa stále jedná a prínosy približne v hodnotách 25 percent. Tieto hodnoty sú relatívnym vyjadrením.

<b>Zhluk 1</b>	<b>Zhluk 2</b>	<b>Zhluk 3</b>
1aa	2aa	3aa
1bb	2bb	3bb
1cc	2cc	3cc
1dd	2dd	3dd
1ee	2ee	3ee
1ff	2ff	3ff
1gg	2gg	3gg
1hh	2hh	3hh
1ii	2ii	3ii
1jj	2jj	3jj
1kk	2kk	3kk
1ll	2ll	3ll
1mm	2mm	3mm
1nn	2nn	3nn
1oo	2oo	3oo
1pp	2pp	3pp
1qq	2qq	3qq
1rr	2rr	3rr
1ss	2ss	3ss
1tt	2tt	3tt
1uu	2uu	3uu
1vv	2vv	3vv
1xx	2xx	3xx
1yy	2yy	
1zz	2zz	
1aaAA	2aaAA	
1bbBB	2bbBB	
1ccCC	2ccCC	
1ddDD	2ddDD	
1eeEE	2eeEE	
1fffF	2fffF	
1ggGG	2ggGG	
1hhhHH	2hhhHH	
1iiiI	2iiiI	
1jjJJ	2jjJJ	
1kkKK	2kkKK	
1llLL	2llLL	
1mmMM		
1nnNN		
1ooOO		
1ppPP		

*Obrázok 34: Zoznam firiem v jednotlivých zhlukoch (pseudo-názvy)*

## 7 Zhodnotenie výsledkov

Vlastný prínos diplomovej práce je spracovanie a vyhodnotenie dotazníkov. Vyhodnotenie pomôže našej firme zlepšiť kvalitu poskytovaných služieb a zvyšovať tak ekonomickú výkonnosť. Po zhodnotení údajov, ktoré nám poskytli naši zákazníci formou dotazníkov, sme dospeli k dvom hlavným zisteniam.

Prvým z nich je komplexné vyhodnotenie spokojnosti zákazníkov. Koncovým výsledkom je tabuľka kvality kurzov. Vo finále sme dostali jednoduchý a prehľadný zoznam kurzov s ich indexom kvality. Plný zoznam sa nachádza v prílohách. Zamerať by sme sa mali hlavne na najlepšie a najhoršie kurzy. Zvláštnu pozornosť musíme venovať hlavne kurzom, ktoré skončili na konci rebríčku. Tam je totiž priestor pre zlepšovanie. Zvyšovanie kvality je v tomto prípade nevyhnutné pre udržanie si stabilnej základne zákazníkov. Je dôležité udržať si vysoký stupeň spokojnosti poskytovaných služieb.

Druhým zistením je rozdelenie zákazníkov do niekoľkých skupín spolu s ich charakteristikami. Celkovo máme tri skupiny. Prvou sú veľké firmy so skúsenými zamestnancami na technických pozíciách. Ich využitie znalostí a zvýšenie výkonu je stredné. Druhou skupinou sú firmy stále pomerne veľké so stredne vzdelanými zamestnancami na technických pozíciách. Využitie znalostí a zvýšenie výkonu je veľmi vysoké. Poslednou a najzaujímavejšou skupinou sú menšie firmy s menej skúsenými zamestnancami na technických a manažérskych pozíciách. U nich je prínos školení nižší. Vzhľadom k menším skúsenostiam zamestnancov v obore by sme práve tu očakávali najvyšší prínos vzdelávania.

### 7.1 Opatrenia

Rebríček hodnotenia kurzov si vyžiada nasledovné opatrenia u najhorších kurzov:

- Dôkladné preštudovanie hodnotení dotazníkov, vrátane textových komentárov
- Vyhľadanie slabých stránok u najhorších kurzov
- Inštrukcie lektorom pre zlepšovanie (viac technických informácií, vlastné príklady,...)
- Zaslanie spätnej väzby vzdelávacím divíziám výrobcom školených technológií
- Revízia a zlepšenie príručiek v prípade vlastných kurzov
- Vytvorenie alternatívneho kurzu vo forme Gopas Official Curriculum
- Vylúčenie kurzu z portfólia (jedine v prípade nízkeho záujmu zo strany zákazníkov)

Kategorizácia zákazníkov si vyžiada tieto opatrenia:

- Zamerať sa najmä na skupinu menších firiem, ktoré sa nachádzajú v zhluku číslo 3 (najmenšie skúsenosti zamestnancov a zároveň najmenší prínos školení)
- Dôkladne preskúmať dotazníky od ich zamestnancov, vrátane komentárov
- Inštrukcie obchodníkom pre ponúkanie školení zameraných na menšie firmy (napríklad MS Small Business Server, Linux, MS Office, ...)
- Ponúkanie kurzov, ktoré zahŕňujú aj licencie ku školeným produktom (MS Server, MS SQL server, ...)



## 8 Záver

Cieľom diplomovej práce bolo spracovať a vyhodnotiť dotazníky, ktoré vyplňajú účastníci kurzu. Sledoval som dva základné ciele a to komplexné vyhodnotenie kvality kurzov a tzv. klasterizáciu zákazníkov. Na dosiahnutie požadovaných výsledkoch som použil metódy umelej inteligencie. V prvom prípade sa jednalo o fuzzy logiku, v druhom prípade som použil neurónové siete. V oboch situáciách som využil už existujúce softwarové prostriedky.

Výsledné hodnotenie nám prinieslo rebríček spokojnosti s kurzami. Ten využijeme na odstránenie slabých miest u horších kurzov. Inšpirovať sa môžeme práve zoznamom najlepších kurzov a ich detailnými hodnoteniami. To je budúca práca produktových manažérov, ktorí sú zodpovední za jednotlivé vyučované oblasti. Napríklad oblasť kancelárskych programov, správa serverov a sietí, databázy, grafika.

Výstupom druhej úlohy sú 3 skupiny firiem, ktoré majú spoločné charakteristiky. V tomto prípade sa musíme zamerať najmä na poslednú skupinu. Jedná sa o zhluk firiem, ktoré majú menší počet počítačov. Ich zamestnanci sú menej skúsenejší ale školenie pre nich nepredstavuje nadštandardný prínos. To je prinajmenšom znepokojujúci fakt. Preto sa musíme zamerať na kurzy, na ktoré sa prihlasujú a dôkladne preskúmať ich komentáre. Úlohou obchodníkov v jednotlivých pobočkách bude presnejšie zacielenie na potreby týchto zákazníkov.

V konečnom dôsledku prispejú zistenia k doručeniu vyššej hodnoty pre zákazníkov. Účastníci kurzu sa tak budú znova vracieť a využívať našich služieb. Sledujeme tým tzv. celoživotnú hodnotu zákazníka – lifetime customer value. Vo finále tak prijaté opatrenia prinesú zvýšený zisk a zlepšia ekonomickú výkonnosť firmy. Verím, že zistené fakty budú užitočné a prospešné pri plnení poslania spoločnosti GOPAS.

# Literatúra

- [1] DOSTÁL, Petr, RAIS, Karel, SOJKA, Zdeněk. Pokročilé metody manažérského rozhodování. Praha : Grada Publishing, 2005. 168 s. ISBN 80-247-1338-1.
- [2] DOSTÁL, Petr. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě. Brno : CERM, 2008. 340 s. ISBN 978-80-7204-605-8.
- [3] ROSS, Timothy. Fuzzy logic with engineering applications. [s.l.] : John Wiley and Sons, 2004. 628 s. ISBN 9780470860755.
- [4] Počítačová škola GOPAS a.s. [online]. 2009 [cit. 2008-05-20]. Dostupný z WWW: <<http://www.gopas.cz/Clanek.aspx?IDClanku=50>>.
- [5] FuzzyTECH [online]. 2009 [cit. 2009-05-20]. Dostupný z WWW: <<http://www.fuzzytech.com/>>.
- [6] Neural Network Software Add-ins for Microsoft Excel [online]. 2003 [cit. 2009-05-20]. Dostupný z WWW: <<http://www.neuroxl.com/>>.
- [7] Justice.cz [online]. 2009 [cit. 2009-05-20]. Dostupný z WWW: <<http://portal.justice.cz/justice2/Uvod/Uvod.aspx>>
- [8] Obchodný register SR [online]. 2009 [cit. 2009-05-20]. Dostupný z WWW: <[http://www.orsr.sk/search\\_subjekt.asp](http://www.orsr.sk/search_subjekt.asp)>.

# Zoznam obrázkov

Obrázok 1: Logo spoločnosti GOPAS.....	5
Obrázok 2: Mobilná učebňa.....	6
Obrázok 3: Učebňa v priestoroch firmy.....	8
Obrázok 4: Organizačná štruktúra GOPAS a.s.....	10
Obrázok 5: Tvary základných členských funkcií.....	16
Obrázok 6: Príklad členskej funkcie.....	16
Obrázok 7: Sčítanie na fuzzy množinách.....	17
Obrázok 8: Odčítanie na fuzzy množinách.....	17
Obrázok 9: Prienik fuzzy množín.....	18
Obrázok 10: Zjednotenie fuzzy množín.....	18
Obrázok 11: Doplnok fuzzy množiny.....	19
Obrázok 12: Proces fuzzy spracovania.....	20
Obrázok 13: Členské funkcie pre percento úročenia.....	20
Obrázok 14: Model umelého neurónu.....	21
Obrázok 15: Priebehy aktivačných funkcií Hardlim a Purelim.....	22
Obrázok 16: Priebehy aktivačných funkcií Logsin a Tansin.....	22
Obrázok 17: Neurónová sieť so skrytými vrstvami.....	23
Obrázok 18: Postup hodnotenia spokojnosti zákazníkov.....	28
Obrázok 19: Fuzzyfikácia vstupných hodnôt.....	30
Obrázok 20: Definovanie vstupov.....	31
Obrázok 21: Fuzzy model.....	32
Obrázok 22: Pravidlá pre prvý blok pravidiel.....	33
Obrázok 23: Členské funkcie pre výpočet výstupu.....	34
Obrázok 24: Stupeň príslušnosti prvého vstupu.....	35
Obrázok 25: Stupeň príslušnosti druhého vstupu.....	35
Obrázok 26: Stupeň zhody s pravidlami.....	36
Obrázok 27: Výstup.....	36

Obrázok 28: Ukážka zhlukovania.....	39
Obrázok 29: Použitie NeuroXL Classifier.....	42
Obrázok 30: Zhlukovanie - závislosť skúseností a využitia znalostí.....	44
Obrázok 31: Zhlukovanie - závislosť zamerania a využitia znalostí.....	45
Obrázok 32: Rozdelenie firiem do jednotlivých zhlukov.....	46
Obrázok 33: Profily zhlukov.....	47
Obrázok 34: Zoznam firiem v jednotlivých zhlukov (pseudo-názvy).....	48

## Zoznam tabuliek

Tabuľka 1: Výpis z obchodného registra ČR.....	7
Tabuľka 2: Výpis z obchodného registra SR.....	9
Tabuľka 3: SWOT analýza.....	12

# **Zoznam príloh**

Príloha 1. Dotazníky pre účastníkov kurzu

Príloha 2. Vstupné údaje z vyhodnotených dotazníkov

Príloha 3. Výsledná tabuľka hodnotenia kurzov